



TITLE:

機械学習によるファジィ推論知識
の自動獲得に関する研究(
Dissertation_全文)

AUTHOR(S):

野村, 竜也

CITATION:

野村, 竜也. 機械学習によるファジィ推論知識の自動獲得に関する研究.
京都大学, 1998, 博士(工学)

ISSUE DATE:

1998-07-23

URL:

<https://doi.org/10.11501/3142217>

RIGHT:

②

機械学習によるファジィ推論知識の 自動獲得に関する研究

野村 竜也

1998 年

論文要旨

システムの設計・制御を行う上で、人間による直接的方法はシステムが大規模かつ複雑になると、非常に困難となる。このため、与えられたデータから自動的に問題となる設計・制御の問題を解決する手法、いわゆる機械学習のアルゴリズムが研究されている。

中でも、複数の入力属性から成るデータの分類規則を例題となる入出力データから自動的に抽出する方法として、ID3 に代表される決定木生成アルゴリズムが研究されている。これは、与えられた出力データの集合を特定の入力属性に着目して入力属性値ごとに分割することにより、帰納的に分類木を生成することで最終的に分類規則を抽出する手法である。しかし、オリジナルの ID3 では入力属性値、出力値共に離散値もしくは記号などの非数値データである場合にしか適用出来ないという制限がある。一方、ファジィ理論の特性を取り入れることにより入力属性値が数値である場合に拡張された方法として、ファジィ決定木を生成することでファジィ If-Then ルールを抽出するファジィ ID3 が提案されている。しかし、知識抽出の対象である入出力データに内在する規則の傾向が動的に変化する場合には、ID3 のような従来のアルゴリズムでは適用が難しい。

このような動的環境における適応システムの構築法として、近年ニューラルネットワークや遺伝的アルゴリズムなどの生物の情報処理を模倣した機械学習アルゴリズム、いわゆる“Biologically Inspired Methods”を用いた手法が提案されている。とくに、近年の大きい流れとして、ファジィの持つ言語的表現能力と Biologically Inspired Methods を組み合わせた適応的知識抽出法の研究が盛んに行われている。本稿では、従来の ID3 が扱えなかった数値入力属性を持つ入出力データにおいて、内在する規則の傾向が動的に変化する場合での、データからのファジィ推論知識の抽出を目標とし、ニューラルネットワーク、遺伝的アルゴリズム、およびそのハイブリッドモデルによるファジィルールの適応的ファジィメタ抽出の手法を与える。

目次

第 1 章	はじめに	4
1.1	概論	4
1.2	入出力データとファジィ If-Then ルールの形式	5
1.3	本稿の構成	7
第 2 章	数値確信度付きファジィルールの数学的性質	8
2.1	はじめに	8
2.2	直接確信度と間接確信度	9
2.2.1	基本記述	9
2.2.2	数値確信度の解釈	12
2.3	直接・間接確信度による各種推論法の性質	13
2.3.1	直接確信度における各種推論法の性質	14
2.3.2	間接確信度における各種推論法の性質	18
2.4	シングルトン形式ルールと従来形式ルールとの比較	21
2.5	考察	26
第 3 章	Fuzzy Self Organizing Map を用いた適応的ファジィルール抽出	28
3.1	はじめに	28
3.2	SOM と FSOM	29
3.2.1	SOM と競合学習	29
3.2.2	FSOM	30

3.2.3	ESOM における実数値の導入	33
3.3	FIN の導入によるルール抽出	36
3.3.1	FIN	36
3.3.2	Radial Basis Function による方式との比較検討	39
3.3.3	遺伝的アルゴリズムによる方式との比較検討	42
3.4	評価環境におけるパフォーマンスと評価	43
3.4.1	他方式との比較実験	44
3.4.2	ESOM における学習アルゴリズムの比較実験	49
3.5	まとめ	53
第 4 章	実数値染色体と偏平均交叉による遺伝的アルゴリズムを用いたファジィルール抽出	56
4.1	はじめに	56
4.2	ルール抽出のための遺伝的アルゴリズムにおける実数値染色体符号化と偏平均交叉	57
4.2.1	実数値符号化	57
4.2.2	偏平均交叉	58
4.2.3	ファジィルール抽出への応用	60
4.3	評価環境におけるパフォーマンスと評価	61
4.3.1	実験 1	61
4.3.2	実験 2	67
4.4	まとめ	72
第 5 章	ハイブリッドシステムを用いたファジィルール抽出	75
5.1	はじめに	75
5.2	ハイブリッドシステムによるファジィルール抽出	76
5.2.1	ESOM-実数値染色体GA-ハイブリッドシステム	76
5.2.2	遺伝的交叉法-ベクトル法-ハイブリッドシステムによるファジィルール抽出	79
5.3	評価環境におけるパフォーマンスと評価	84

5.4	考察	84
第 6 章	おわりに	85
6.1	まとめ	85
6.2	今後の課題	86
参考文献		88
本研究に関する公表文献		93
謝辞		96

第1章 はじめに

1.1 概論

システムの設計・制御を行う上で、人間による直接的方法はシステムが大規模かつ複雑になるにつれて非常に困難となる。そのため、与えられたデータから自動的に問題となる設計・制御の問題を解決する方法、いわゆる機械学習アルゴリズムが研究されている。

機械学習は非常に多様な分野であり、その目的も多様である。その1つの流れとして、システムが自分のパフォーマンスをモニターし、それに応じて内部パラメータを自動的に修正する適応システムがあり、別の流れとして、システム外部から与えられたデータに内在する規則性を構造化し、明示的な知識を獲得する知識抽出システムがある。この2つの流れは独立なものではなく、一方がその目的のために他方を利用するものも考えられる。

複数の入力属性から成るデータ分類規則を例題となる入出力データから自動的に抽出する方法は、主に人工知能分野において研究されている。このような手法の主流の1つに、ID3 [27] に代表される決定木生成アルゴリズムがある。これは、与えられた入出力データの集合を特定の入力属性に着目して入力属性値ごとに分割することにより、帰納的に分類木を生成することで最終的に分類規則を抽出する手法である。ID3の特徴は、相互情報量を用いて最も分類効率の良い入力属性を選択することにある。しかし、オリジナルのID3には、入力属性値、出力値共に離散値もしくは記号などの非数値データである場合に適用出来ないという制限がある。

一方、人間が用いる曖昧な知識を数理的に表現する方法として、ファジ理論が30年以上前に提唱されている。このファジ理論の特性を取り入れることにより上記の弱点を補い、入力属性値が数値である場合に拡張されたファジID3、あるいは拡張されたファジID3の集合により入出力集合をファジID3で分割し、ファジID3決定木を生成するファジID3 If-Thenルールを抽出するファジID3-IF [50]が提案されている。入

出力集合をファジID3で分割する際のファジID3集合を入力属性数値の分布によって自動的に決定するアルゴリズムを含めたファジID3-IDF [50]も提案されている。

しかし、上記の知識抽出システムと適応システムを同時に実現しなければならない場合、とくに、知識抽出の対象である入出力データに内在する規則の傾向が動的に変化する場合では、ID3のような従来のアルゴリズムでは適用が難しい。つまり、ID3などの決定木方式では、規則の傾向が変化する度に最初から決定木を組み直す必要があり、適応性に欠けるからである。

このような動的環境における適応システムの構築法として、近年ニューラルネットワークや遺伝的アルゴリズムなどの生物の情報処理を模倣した機械学習アルゴリズム、いわゆる“Biologically Inspired Methods”を用いた手法が提案されている。これは、生物の適応能力を何らかの形で実現し柔軟な適応システムを構築する試みであるが、それぞれの手法の理論的解析が難しいため、工学分野では実証的研究が急がれている。とくに、近年の大きい流れとして、ファジID3の持つ言語的表現能力と Biologically Inspired Methodsを組み合わせた適応的知識抽出法の研究が盛んに行われている。これは、ファジID3自体には無い学習能力を、上記手法によって補うことを特徴としている。

本稿では、従来のID3が扱えなかった数値入力属性を持つ入出力データにおいて、内在する規則の傾向が動的に変化する場合での、データからのファジID3推論知識の抽出を目標としている。具体的には、与えられた複数の数値入力属性から成る入出力データの集合から、ファジID3と同様にファジID3 If-Thenルールの形式で知識抽出を行うことを目的として、ニューラルネットワーク、遺伝的アルゴリズム、およびそのハイブリッドモデルによるファジID3ルールの適応的パラメータ抽出の手法を考える。

1.2 入出力データとファジID3 If-Then ルールの形式

本稿では、 n 個の実数値入力属性を持ち、1 個の出力値を持つ入出力データとその集合

$$S^{(l)} = (a_{l1}, a_{l2}, \dots, a_{ln}; c_l) \quad (l = 1, \dots, N)$$

$$S = \{S^{(1)}, S^{(2)}, \dots, S^{(N)}\} \quad (N: \text{入出力データの総数})$$

を考える。ここで、入力属性ベクトル $a_l = (a_{l1}, \dots, a_{ln})$ は n 次元ユークリッド空間 \mathbf{R}^n に属し、出力値 c_l は L 種類の離散値もしくは記号の値 $\{C_1, C_2, \dots, C_L\}$ のいずれかをとるものとする。また、 a_{li}

出力値集合 S を出力値が同一データの部分集合に分割したもの

$$S_k = \{S^l \in S : c_l = C_k\} \quad (k = 1, \dots, L) \quad (1.2)$$

考える．このデータ構造はフuzzy ID3 が扱うのと同じものであるが，本稿では各出力値に対応する入力データの傾向が動的に変化する場合，つまり各 S_k に属する S^l の入力属性ベクトル $a_l = (a_{l1}, \dots, a_{ln})$ が体分布が時間的，変化する場合を想定する．

フuzzy ID3 では，各数値属性において幾つかのファジィ集合が，つまり1次元ユークリッド空間上の複数のファジィ集合 $\{F_1^k, \dots, F_{n_k}^k\} (k = 1, \dots, m)$ が予め定義されており，それによって，式(1.2)に示す入出力データ集合をフuzzy分割を相互情報量を用いて行う．この手法では，最終的に以下の形式の数値確信度付きのシングルトン型後件部を持つファジィIf-Thenルールが抽出される．

$$\text{If } I_1 \text{ is } I_{j_1}^{i_1} \text{ and } I_{i_2} \text{ is } I_{j_2}^{i_2} \text{ and } \dots \text{ and } I_{i_d} \text{ is } I_{j_d}^{i_d}, \text{ Then } c \text{ is } C_h \text{ with weight } \omega$$
$$(1 \leq i_1 + \dots + i_d \leq n, 1 \leq j_l \leq n_{i_l} (l = 1, \dots, d))$$

ここで，後件部は有限集合 $C = \{C_1, \dots, C_L\}$ 上のシングルトン型ファジィ集合(C_k 上で1, それ以外では0の値を持つ)であり，また， ω はルールに対する数値確信度であり，ルールの信頼性を表している．

本稿ではフuzzy ID3での知識表現を踏襲する形で，式(1.2)に示す入出力データから以下の形式の数値確信度付きのシングルトン型後件部を持つファジィIf-Thenルールを抽出する．

$$\text{If } I_1 \text{ is } I_{ki1} \text{ and } I_2 \text{ is } I_{ki2} \text{ and } \dots \text{ and } I_n \text{ is } I_{kin}, \text{ Then } c \text{ is } C_k \text{ with weight } \omega_{ki} \quad (1.3)$$

$$\sum \omega_{ki} = 1 \quad (k = 1, \dots, L, i = 1, \dots, m)$$

ここで，后件部は各 I_k は1次元ユークリッド空間上のファジィ集合であり，後件部は有限集合 $C = \{C_1, \dots, C_L\}$ 上のシングルトン型ファジィ集合(C_k 上で1, それ以外では0の値を持つ)である．また， ω はルールに対する数値確信度である．このルール群においては，各出力値を後件部に持つルールが m 個ずつ，合計 $L \times m$ 個のルールが存在し，数値確信度はこの m 個のルール内で正規化条件を満たしている．また，今後，よくにこしわらない限り， I_k は以下ガウス型メンバシップ関数

$$I_k(x) = \exp\left(-\frac{1}{2} \left(\frac{\mu - x}{\sigma}\right)^2\right) \quad (k = 1, \dots, L, i = 1, \dots, m, j = 1, \dots, n) \quad (1.4)$$

を持つとする．

ここで問題となるのは，式(1.3)のファジィ推論規則群で表現される知識が，どの程度の普遍性を持っているかということ，および式(1.3)，(1.4)における数値パラメータ μ_{ki} ， σ_{ki} ， ω_{ki} ，データの傾向変動に追尾しながらどのように適応的に調整することである．本稿では，前者の問題は，従来形式のファジィ推論規則との数値的対比により検証し，後者の問題に対しては，遺伝的アルゴリズム，ニューラルネットワーク，遺伝的アルゴリズムによる適応的機械学習の手法を提案することにより対処する．

1.3 本稿の構成

本稿の構成は以下の通りである．

まず，第2章において，前章の式(1.3)の形式の数値確信度付きファジィIf-Thenルールの形式が従来のファジィIf-Thenルールとどのような関係にあるかを数値的に解析し，知識抽出の形式として妥当なものであるかどうかを検証する．

次に，第3章において，ファジィクラスタリングの手法としてKohonen's Self-Organizing Mapを拡張したファジィニューラルネットワーク“Fuzzy Self-Organizing Map”を用いて，式(1.3)の形式のルールを直接表現するニューラルネットワークを構成する．また，このニューラルネットワークを用いて前章の式(1.1)の形式の実験データから学習を行い，他の比較方式と対比しながら，その性能を検証する．

第4章においては，式(1.3)のルールを遺伝的アルゴリズムによって抽出する手法を用いる．この手法では，従来の染色体符号化と異なる実数値染色体表現を採用し，さらにそれに適した交叉(偏平均交叉)を用いる．また，これらを用いた遺伝的アルゴリズムと従来方式との比較実験を行い，その性能を検証する．

さらに，第5章では第3章におけるニューラルネットワークと第4章における遺伝的アルゴリズムを併用した遺伝的進化のハイブリッドモデルを用いて，単体方式との比較実験を行い，その性能を検証する．

最後に，第6章において本方式の問題点および今後のあり方について議論する．

第2章 数値確信度付きファジィルールの数学的性質

2.1 はじめに

近年、スマートシステムにおいて、確信度を示す数値もしくはファジィ数が付与された形式のファジィルールが使用されている事例が存在する [44, 42, 41, 39, 48, 21]. とくに、ニューラルネットワークや遺伝的アルゴリズムによるファジィ If-Then ルールの抽出において、数値確信度が与えられているルールが用いられている事例が存在する [42, 39–48, 21].

そのような数値確信度付きルールの推論合成においては、基本的に Zadeh の直接法による \max - \min 推論, \max 代数積推論などが用いられている. しかし、一般的な T-ノルムによる推論合成における性質は、Zadeh 法以外の推論法における数値確信度の解釈に関する議論は為されていない. また、文献 [39–48, 21] では、多次元データのクラスタリングを目的としたファジィ If-Then ルールにおいて、後件部メンバシップ関数がシングルトン形式のものを取り扱っているが、この形式のルールと従来の形式のルールの表現能力の比較は為されていない.

文献 [38] では、クリスフ入力に対して複数の規則に対する \max 代数積による推論結果を加算合成し重心値を出力する方法、つまり、各関数を代数積とした直接推論と加算、中心法による合成を用いた場合、従来のファジィルールと後件部がシングルトン型のルールが同等であることが示されている. 本稿においては、後件部メンバシップ関数の定義域集合が有限集合の場合に、数値確信度の付与された後件部がシングルトン形式のファジィ If-Then ルールと従来の形式のルールが同等となるための T-ノルム, 各関数の条件を、数値確信度の解釈、各解釈における Zadeh の直接法, Baldwin, 塚本の間接法による各推論法について検証する. つまり、前記の式 (1.3) で示される形式のファジィ推論規則

の一般性に関する検証を行う. ただし、本章では式 (1.4) のガウス型メンバシップ関数を仮定しない.

そのため、まず後件部メンバシップ関数の定義域集合が有限とは限らない一般的な場合において、ルールに付与された数値確信度に2通りの解釈、直接確信度と間接確信度の場合を考え、各々の場合において、Zadeh, Baldwin, 塚本の各推論法を適用し、各推論法による結論の間の関係、確信度を持たない従来の形式のルールによる結論との関係について検証する. その後、後件部がシングルトン形式の数値確信度付きファジィ If-Then ルールと従来の形式のルールが同等となるための条件を導出し、それに基づいて、本稿で採用する式 (1.3) のファジィ If-Then ルールの一般性について議論する.

2.2 直接確信度と間接確信度

2.2.1 基本記述

本章に限り、以下の記述を使用する.

$F(S)$: 任意の集合 S 上のファジィ集合の全体

$\mu_{FS} : S \rightarrow [0, 1] : F \in F(S)$ のメンバシップ関数

以降、 X_i を i 番目の入力の全体集合 ($i = 1, \dots, n$), $X = X_1 \times \dots \times X_n$, Y を出力の全体集合とする. 本章では、以下の形式の多次元ファジィ If-Then ルールの群

$$H_i : \text{If } x_1 \text{ is } A_{i1} \text{ and } \dots \text{ and } x_n \text{ is } A_{in}, \text{ then } y \text{ is } B_i \quad (i = 1, \dots, m)$$

と、 H_i に数値確信度 W_i ($i = 1, \dots, m$) が付与されたルールの群

$$R_i : \text{If } x_1 \text{ is } A_{i1} \text{ and } \dots \text{ and } x_n \text{ is } A_{in}, \text{ then } y \text{ is } B_i \text{ with } W_i \quad (i = 1, \dots, m)$$

を考えよう. ここで、 $x_j \in X$, $y \in Y$, $A_{ij} \in F(X_j)$, $B_i \in F(Y)$, $W_i \in [0, 1]$ である.

また、 Y が有限集合 $\{y_1, y_2, \dots, y_L\}$ の場合におけるシングルトン形式ルールの群

$$H = \{H_i : \text{If } x_1 \text{ is } A_{i1} \text{ and } \dots \text{ and } x_n \text{ is } A_{in}, \text{ then } y \text{ is } y_k \\ (A_{ik} \in F(X_j) \quad k = 1, \dots, L, i = 1, \dots, m)\}$$

に於て，各値確信度 W_k ($k = 1, \dots, L, i = 1, \dots, m_k$) が付与されたルール群

$$R_i: \text{If } x_1 \text{ is } A_{k_1} \text{ and } \dots \text{ and } x_n \text{ is } A_{k_n}, \text{ then } y \text{ is } y_k \text{ with } W_{ki} \\ (k = 1, \dots, L, i = 1, \dots, m_k)$$

を考慮し，式(13)のルールは，この型に属し，各入力属性が実数空間であり，ガウス型メンバシップ関数を持つ特別な場合に対応している。

推論過程において，含意関数

$$I: [0, 1] \times [0, 1] \rightarrow [0, 1]$$

によつて， I -ノルム

$$I: [0, 1] \times [0, 1] \rightarrow [0, 1]$$

が与えられているとする。 I は， $I(a, b) = a * b$ と記述する時，以下の条件を満たす2項関数 $*$ により規定される[51]。

$$(T1) \ a * 1 = a \ (\forall a \in [0, 1])$$

$$(T2) \ a * c, b * d = a * b * c * d$$

$$(T3) \ a * b = b * a \ (\forall a, b \in [0, 1])$$

$$(T4) \ a * (b * c) = (a * b) * c \ (\forall a, b, c \in [0, 1])$$

$$((T1)(T2) \text{ より}, \ 0 * b = 0 \ (\forall b \in [0, 1]))$$

ここで，含意関数 I にはとくに与わらない限り条件は付けないとする。

また，真理値空間 $[0, 1]$ 上の部分集合 $F(X)$ を「真理値」呼ぶ， $FV \in F([0, 1])$ に対するメンバシップ関数 $\tau_{FV}: [0, 1] \rightarrow [0, 1]$ 置く。例えば，

$$\tau_{I = (r)}(r) = r \ (\forall r \in [0, 1]), \ \tau_{A \leq 0.5 \text{ or } I = (r)}(r) = \begin{cases} 1 & (r = 1) \\ 0 & \text{otherwise} \end{cases}$$

とある。

今，任意の前提フージ集合 $A'_i \in F(X_i)(i = 1, \dots, n)$ が与えられているとする。以て， $A' = A'_1 * \dots * A'_n \in F(X)$ を A'_1, \dots, A'_n の I -ノルム $*$ による直積

$$\mu_{A'}(x) = \mu_{A'_1}(x_1) * \mu_{A'_2}(x_2) * \dots * \mu_{A'_n}(x_n) \ (\forall x = (x_1, \dots, x_n) \in X)$$

とする。また，各ルール H_i, R_i, H_k, R_{ki} において， $A_i = A_{i1} * \dots * A_{ir}$, $A_k = A_{k1} * \dots * A_{kr}$ と略記する。以下の各推論の規則モードスハーネンス

$$\begin{array}{l} \text{前提:} \quad x_1 \text{ is } A'_1, \dots, x_n \text{ is } A'_n \\ \hline \text{規則:} \quad H_i \\ \hline \text{結論:} \quad y \text{ is } B'_i \end{array}$$

において結論のフージ集合 B'_i を置くために，Zadeh の推論法(直接法)，Baldwin の推論法，塚本の推論法(間接法)が提案されている[35]。

Zadeh の直接推論法では，規則 H_i は $X \times Y$ 上のファシイ関係 $A_i \Rightarrow B_i$ を与えと考え，推論結果を以下の式で与える。

$$\mu_{B'_i}(y) = \sup_{x \in X} \mu_{A'}(x) * I(\mu_{A'}(x), \mu_{B_i}(y)) \tag{2.1}$$

一方，Baldwin，塚本の間接推論法では，前提“ x is A' ”から R_i の前提 x is A_i に対する含意真理値 $\tau_{A_i} \in F([0, 1])$ を逆真理値限定により以下の式で定める。

$$\tau_{A_i}(a) = \sup_{\substack{x \in X \\ \mu_{A_i}(x) = a}} \mu_{A'}(x) \ (\forall a \in [0, 1]) \tag{2.2}$$

この τ_{A_i} と含意関数から R_i の後件部“ y is B_i ”に対するフーシイ真理値 $\tau_{B_i} \in F([0, 1])$ を定め，真理値限定により以下の推論結果を与える。

$$\mu_{B'_i}(y) = \tau_{B_i}(\mu_{B_i}(y)) \ (\forall y \in Y) \tag{2.3}$$

Baldwin の推論法では，

$$\tau_{B'}(b) = \sup_{a \in [0, 1]} \tau_{A'}(a) * I(a, b) \tag{2.4}$$

と定められる。また，塚本の推論法では，任意の命題“ $\text{If } P \text{ is } P, \text{ then } y \text{ is } Q$ ” ($P \in F(X), Q \in F(Y)$) に対するフーシイ真理 $\tau_{P \Rightarrow Q} \in F([0, 1])$ を

$$\tau(r) = \tau_{I \Rightarrow Q}(r) = \sup_{\substack{a \in [0, 1], \\ I = a}} \tau_I(a) * \tau_Q(b) \ (\tau_I, \tau_Q \in F([0, 1])) \tag{2.5}$$

— 定め,

$$\tau_{B_i}(b) = \sup_{\substack{a \in [0,1] \\ I(a,b)=1}} \tau_{A_i}(a) * \tau_{A_i \Rightarrow B_i}(c) = \sup_{\substack{(a,b) \in [0,1]^2 \\ I(a,b)=1}} \tau_{A_i}(a) * \tau(c) \quad (2.6)$$

す。

また, 合計 m 個の Modus Ponense の結論 B'_1, B'_2, \dots, B'_m を最終的に 1 つの結論に合成する手法として, 本章では以下の \max による合成 B'_{\max} と加算による合成 B'_{sum} の 2 つの場合を取り扱う。

$$\mu_{B'_{\max}}(y) = \max_{i=1}^m \mu_{B'_i}(y) \quad (y \in Y) \quad (2.7)$$

$$\mu_{B'_{\text{sum}}}(y) = \sum_{i=1}^m \mu_{B'_i}(y) \quad (y \in Y) \quad (2.8)$$

2.2.2 数値確信度の解釈

この章では, 上記の数値確信度付きファジィ If Then ルール R_i における確信度の解釈について議論を進める。

直接確信度

この解釈は, 数値確信度を従来形式のルールに埋め込む形のものである。つまり, ルール R_i において, 以下のように W_i が後件部にかかると解釈する。

$$R_i: \text{If } x_1 \text{ is } A_{i1} \text{ and } \dots \text{ and } x_n \text{ is } A_{in}, \text{ then } y \text{ is } C_i = W_i * B_i$$

ここで, C_i は集合 $C_i \subseteq I(Y)$ を以て定義する。

$$\mu_{W_i * B_i}(y) = W_i * \mu_{B_i}(y) \quad (\forall y \in Y) \quad (2.9)$$

つまり, C_i は $\mu_{W_i}(y) = W_i \quad (\forall y \in Y)$ なるファジィ集合 $\overline{W_i}$ と B_i との $*$ による結合である。

この解釈では, R_i は従来形式のルールと見なせるので, Zadeh, Baldwin, 塚本の推論法をそのまま適用出来る。

間接確信度

この解釈では, 確信度なしの従来形式のルールに対する推論において, 推論の段階で数値確信度が影響する。

Zadeh の推論法では, R_i から確信度を取り去った従来形式のルール H_i に対して, 確信関数を新たに

$$J_{W_i}(a, b) = W_i * I(a, b) \quad (2.10)$$

として, 式 (2.1) において I を J_{W_i} に置き換えて推論法を適用する。

Baldwin, 塚本の推論法では, 式 (2.3) における τ_{B_i} において数値確信度が影響する。Baldwin の推論法では, 式 (2.4) において I を上記 J_{W_i} に置き換えて推論法を適用する。また, 塚本の推論法においては, 式 (2.6) の I を J_{W_i} に, $\tau = \tau_{A_i \Rightarrow B_i}$ を新たに定義される $\tau_{(A_i \Rightarrow B_i) = W_i}$ に置き換えて適用する。ここで, 任意の命題

“If x is P , then y is Q with W ” ($P \in F(X), Q \in F(Y), W \in [0, 1]$) に対するファジィ真理値 $\tau_{(P \Rightarrow Q) = W} \in F([0, 1])$ の定義は, 以下の 3 種類を考える。

$$\tau_W^1(r) = \sup_{\substack{(a,b) \in [0,1] \\ J_W(a,b)=r}} (W * \tau_1(a) * \tau_2(b)) \quad (2.11)$$

$$\tau_W^2(r) = \tau_{P \Rightarrow Q}(r) = \tau(r) \quad (2.12)$$

$$\tau_W^3(r) = \sup_{\substack{c \in [0,1] \\ W * c = r}} W * \tau(c) \quad (2.13)$$

Zadeh の直接法, Baldwin の間接法における直接確信度, 間接確信度の推論への影響を, 図 2.1, 2.2 に示す。これらの図においては, $*$ = min を想定している。

2.3 直接・間接確信度による各種推論法の性質

以降, 前提 A' と数値確信度付きルール R_i が与えられた時の, 直接確信度による Zadeh, Baldwin, 塚本の推論法による結論を, それぞれ ZC_i, B_i, IC_i , 間接確信度による Zadeh, Baldwin, 塚本の推論法による結論を, それぞれ $IZC_i, IBC_i, IdIC_i (d = 1, 2, 3)$ とする。ここで, $IdIC_i$ は塚本の推論法において τ_W を使用したときの推論結果である。また, 前提 A' と R_i から確信度を取り去った従来型ル




図 2.1: 直接法による推論での直接，間接確信度の影響

ル H_i が与えられたときの，Zadeh，Baldwin，塚本の推論法による結論を， ZB_i, BB_i, TB_i とする．本稿では，これら各種推論による結果の間の関係について示す．

2.3.1 直接確信度における各種推論法の性質

式 (2.1) (2.6) および (2.9) より，フーシ集合 $ZB_i, BB_i, TB_i, ZC_i, BC_i, TC_i$ は以下の式で定義される．

$$\mu_{ZB_i}(y) = \sup_{x \in X} \mu_{A'}(x) * I(\mu_{A_i}(x), \mu_{B_i}(y)) \quad (2.14)$$

$$\mu_{BB_i}(y) = \sup_{a \in [0, 1]} \tau_{A_i}(a) * I(a, \mu_{B_i}(y)) \quad (2.15)$$

$$\mu_{TB_i}(y) = \sup_{\substack{a, c \in [0, 1] \\ I(a, c) = 1}} \tau_{A_i}(a) * \tau(c) \quad (2.16)$$

$$\mu_{ZC_i}(y) = \sup_{x \in X} \mu_{A_i}(x) * I(\mu_{A_i}(x), \mu_{C_i}(y)) = \sup_{x \in X} \mu_{A_i}(x) * I(\mu_{A_i}(x), W * \mu_{B_i}(y)) \quad (2.17)$$

$$\mu_{BC_i}(y) = \sup_{a \in [0, 1]} \tau_{A_i}(a) * I(a, \mu_{C_i}(y)) = \sup_{a \in [0, 1]} \tau_{A_i}(a) * I(a, W * \mu_{B_i}(y)) \quad (2.18)$$

$$\mu_{TC_i}(y) = \sup_{\substack{a, c \in [0, 1] \\ I(a, c) = 1}} \tau_{A_i}(a) * \tau(c) = \sup_{\substack{a, c \in [0, 1] \\ I(a, W * \mu_{B_i}(y)) = 1}} \tau_{A_i}(a) * \tau(c) \quad (2.19)$$

そこで，以下 [51] より，いくつか重要な命題および定理を引用する．




図 2.2: 間接法による推論での直接，間接確信度の影響

補題 1 $\{a_i : i \in M\} \subset [0, 1]$ (M : 任意のインデックス集合) に対して，

$$\sup_{i \in M} (a_i * b) = (\sup_{i \in M} a_i) * b \quad (\forall b \in [0, 1])$$

また， f が左連続，つまり $f_b : [0, 1] \rightarrow [0, 1] (f_b(a) = a * b)$ が任意の $b \in [0, 1]$ に対して連続かつ，

$$\sup_{i \in M} (a_i * b) = (\sup_{i \in M} a_i) * b \quad (\forall b \in [0, 1])$$

定理 1 (川瀬・柳原の定理 [51]) $ZB_i \subset BB_i$ (i.e., $\mu_{ZB_i}(y) \leq \mu_{BB_i}(y)$ ($\forall y \in Y$)) .

また， f が左連続ならば， $ZB = BB$.

注 1 この定理の対象とするルールの後件部ファシイ集合 $B_i \in F(Y)$ は任意であるから, ZC_i, BC_i についても同じことが成立する.

また, 文献 [35] から以下の補題を拡張引用する.

補題 2 式 (2.5) において以下の条件が成立すれば, $\tau = \tau_{Tru}$.

1. $I(1, b) \leq I(a, b) \ (\forall a, b)$
2. $I(1, b) = b \ (\forall b \in [0, 1])$
3. $\tau_1 = \tau_2 = \tau_{Tru}$

(証明 ([35] 参照)) 条件 (2) より, $I(1, r) = r$. よって, 条件 (3) および (T1)(T3) より,

$$\tau(r) = \sup_{I(a,b)=r} (a * b) \geq 1 * r = r$$

条件 (1)(2) および (T2) より,

$$I(a, b) = r \quad b = I(1, b) \leq I(a, b) = r \Rightarrow a * b \leq 1 * r = r$$

よって, $\tau(r) = r$ が得られる.

(証明終)

上記補題は, 文献 [35] における補題を一般の I ノルムにまで拡張したものである.

定理 2 (陳・柳原・川瀬の定理 [35] の拡張) $\tau = \tau_{Tru}$ ならば, $BB_i = TB_i$.

(証明 ([35] 参照)) 式 (2.16) より

$$\begin{aligned} \mu_{TB_i}(y) &= \sup_{\substack{a \in [0,1] \\ I(a, \mu_{B_i}(y)) = \tau}} \tau_{A_i}(a) * \tau(c) \\ &= \sup_{\substack{a \in [0,1] \\ I(a, \mu_{B_i}(y)) = \tau}} \tau_{A_i}(a) * c = \sup_{a \in [0,1]} \tau_{A_i}(a) * I(a, \mu_{B_i}(y)) \\ &= \mu_{BB_i}(y) \end{aligned}$$

となる.

(証明終)

また, 以下の補題を準備する.

補題 3 以下の条件が成立すれば, $\tau = \tau_I$.

1. $\tau_1 = \tau_2 = \tau_{Tru}$
2. $I(a, b) = a * b \ (\forall a, b \in [0, 1])$

(証明) (T1) より $\{(a, b) \in [0, 1]^2 : a * b = r\} \neq \emptyset \ (\forall r \in [0, 1])$. よって, 条件 (1)(2) より

$$\tau(r) = \sup_{\substack{(a,b) \in [0,1]^2 \\ a * b = r}} a * b = r$$

となる.

(証明終)

補題 2 および 3 より, 以下の系が成り立つ.

系 1 以下の条件が成立すれば, $BB_i = TB_i$.

1. $I(1, b) \leq I(a, b) \ (\forall a, b)$
2. $I(1, b) = b \ (\forall b \in [0, 1])$
3. $\tau_1 = \tau_2 = \tau_{Tru}$

系 2 以下の条件が成立すれば, $BB_i = IB_i$.

1. $\tau_1 = \tau_2 = \tau_{Tru}$
2. $I(a, b) = a * b \ (\forall a, b \in [0, 1])$

注 2 この定理および系の対象とするルールの後件部ファシイ集合 $B_i \in F(Y)$ は任意であるから, BC_i, TC_i についても同じことが成立する.

Zadeh の推論法による R_i の結論と H_i の結論との間には, 以下の関係が成立する.

定理 3 以下の条件が成立すれば, $ZC_i = W_i * ZB_i = W_i * BB_i = BC_i$.

1. $*$ が左連続
2. $I(a, u * b) = u * I(a, b) \ (\forall a, b, u \in [0, 1])$

(証明) (T3)(T4), 補題 (1) および条件 (1) (2) より, 式 (2.17), (2.18) から

$$\mu_{ZC_i}(y) = W_i * \sup_{x \in X} \mu_{A_i}(x) * I(\mu_{A_i}(x), \mu_{B_i}(y)) = W_i * \mu_{ZB_i}(y)$$

$$\mu_{BC_i}(y) = W_i * \sup_{a \in [0,1]} \tau_{A_i}(a) * I(a, \mu_{B_i}(y)) = W_i * \mu_{BB_i}(y)$$

したがって、また、定理 1 およびその注より、 $ZB_i = BB_i$, $\neg C_i = BC_i$ となる。 (証明終)

定理 2 およびその系 2 より、次の系が得られる。

系 1 以下の条件が成立すれば、 $\neg C_i = BC_i = IC_i = W_i * ZB_i = W_i * BB_i = W_i * IB_i$ 。

1. $*$ が左連続
2. $\tau = \tau_{I \rightarrow u}$
3. $I(a, u * b) = u * I(a, b) \quad (\forall a, b, u \in [0, 1])$

系 2 以下の条件が成立すれば、 $\neg C_i = BC_i = IC_i = W_i * ZB_i = W_i * BB_i = W_i * IB_i$ 。

1. $*$ が左連続
2. $\tau_1 = \tau_2 = \tau_{I \rightarrow u}$
3. $I(a \rightarrow b) = a \rightarrow b \quad (\forall a, b \in [0, 1])$

定理 3 の条件を満たすとして、例として、 $*$ = \min , \times , $I(a, b) = a * b$ が挙げられる。

2.3.2 間接確信度における各種推論法の性質

式 (2.1) (2.6) および (2.10) (2.13) より、 $IZC_i, IBC_i, ITC_i (d = 1, 2, 3)$ は以下の式で定義される。

$$\mu_{IZC_i}(y) = \sup_{x \in X} \mu_{A_i}(x) * W_i * I(\mu_{A_i}(x), \mu_{B_i}(y)) \quad (2.20)$$

$$\mu_{IBC_i}(y) = \sup_{a \in [0,1]} \tau_{A_i}(a) * W_i * I(a, \mu_{B_i}(y)) \quad (2.21)$$

$$\mu_{ITC_i}(y) = \sup_{\substack{c \in [0,1] \\ W_i * I(\mu_{A_i}(y), c) =}} \tau_{A_i}(a) * \tau_{W_i}(c) \quad (d = 1, 2, 3) \quad (2.22)$$

補題 1 および定理 1 より、以下の定理が導かれる。

定理 4 $*$ が左連続ならば、 $IC_i = W_i * IB_i = W_i * BB_i = IBC_i$ 。

また、定理 4 および定理 3 より以下の定理が導かれる。

定理 5 以下の条件が成立すれば、 $IZC_i = W_i * ZB_i = W_i * BB_i = IBC_i = \neg C_i = BC_i$ 。

1. $*$ が左連続
2. $I(a, u * b) = u * I(a, b) \quad (\forall a, b, u \in [0, 1])$

また、以下の定理が導かれる。

定理 6 $\{c \in [0, 1] : W_i * c = r\} \neq \emptyset$ なる r に対して、

$$\tau_{W_i}^d(r) = \tau_{I \rightarrow u}(r) = r \text{ が成り立つならば、} I_dTC_i = IBC_i \text{。}$$

さらに、 $*$ が左連続ならば、 $I_dTC_i = IBC_i = W_i * BB_i = W_i * IB_i = I \neg C_i$ 。

(証明)

$$\begin{aligned} \mu_{I_dTC_i}(y) &= \sup_{a \in [0,1]} \tau_{A_i}(a) * \tau_{W_i}^d(W_i * I(a, \mu_{B_i}(y))) = \sup_{a \in [0,1]} \tau_{A_i}(a) * W_i * I(a, \mu_{B_i}(y)) \\ &= \mu_{IBC_i}(y) \end{aligned}$$

後半は定理 4 より明らか。 (証明終)

ここで、以下の補題を準備する。

補題 4 $\tau = \tau_{I \rightarrow u}$ ならば、 $\{c \in [0, 1] : W_i * c = r\} \neq \emptyset$ なる r に対して、 $\tau_{W_i}^3(r) = \tau_{I \rightarrow u}(r)$ 。

(証明) $\tau_{W_i}^3(r) = \sup_{\substack{c \in [0,1] \\ W_i * c = r}} W_i * c = r$ 。 (証明終)

補題 5 以下の条件が成立すれば、 $\{c \in [0, 1] : W_i * c = r\} \neq \emptyset$ なる r に対して、 $\tau_{W_i}^1(r) = \tau_{I \rightarrow u}(r)$ 。

1. $I(1, b) \leq I(a, b) \quad (\forall a, b)$
2. $I(1, b) = b \quad (\forall b \in [0, 1])$
3. $\tau_1 = \tau_2 = \tau_{I \rightarrow u}$

(証明) 条件 (2) より、 $W_i * c = r$ ならば $W_i * I(1, c) = r$ 。よって、条件 (3) および (11)(12) より、

$$\tau_{W_i}(r) = \sup_{W_i * I(1, c) = r} W_i * a * b = W_i * 1 * c = r$$

条件 (1)(2) および (T1) – (T4) より,

$$W_i * I(a, b) = r \Rightarrow W_i * b = W_i * I(1, b) \leq W * I(a, b) = r \Rightarrow W_i * a * b \leq 1 * r = r$$

よって, $\tau(r) = r$ が得られる. (証明終)

補題 6 以下の条件が成立すれば, $\{c \in [0, 1] : W_i * c = r\} \neq \emptyset$ なる r に対して, $\tau_{W_i}^1(r) = \tau_{Tru_i}(r)$.

1. $\tau_1 = \tau_2 = \tau_{Tru}$
2. $I(a, b) = a * b \quad (\forall a, b \in [0, 1])$

(証明) (T1) より $\{(a, b) \in [0, 1]^2 : W_i * a * b = r\} \neq \emptyset \quad (\forall r \in [0, 1])$. よって, 条件 (1)(2) より

$$\tau(r) = \sup_{\substack{(a, b) \in [0, 1]^2 \\ W_i * a * b = r}} W_i * a * b = r$$

補題 2, 3, 4, 5, 6 と定理 2, 3, 6 より, 以下の系が導かれる. (証明終)

系 1 $\tau = \tau_{Tru_i}$ ならば, $I_2IC_i = I_3IC_i = IBC_i$.

さらに, $*$ が左連続ならば, $I_1IC_i = I_3IC_i = IZC_i = IBC_i = W_i * ZB_i = W_i * BB_i = W_i * TB_i$.

系 2 以下の条件が成立すれば, $I_1IC_i = I_2IC_i = I_3IC_i = IBC_i$.

1. $I(1, b) = I(a, b) \quad (\forall a, b)$
2. $I(1, b) = b \quad (\forall b \in [0, 1])$
3. $\tau_1 = \tau_2 = \tau_{Tru}$

さらに, $*$ が左連続ならば, $I_1IC_i = I_2IC_i = I_3IC_i = IBC_i = IZC_i = W_i * BB_i = W_i * ZB = W_i * IB$.

系 3 以下の条件が成立すれば, $I_1IC_i = I_2IC_i = I_3IC_i = IBC_i$.

1. $\tau_1 = \tau_2 = \tau_I$
2. $I(a, b) = a * b \quad (\forall a, b \in [0, 1])$

さらに, $*$ が左連続ならば, $I_1TC_i = I_2TC_i = I_3IC_i = IBC_i = IZC_i = W_i * BB_i = W_i * ZB = W_i * TB_i = ZC_i = BC_i = TC_i$.

2.4 シングルトン形式ルールと従来形式ルールとの比較

この章では, Y は有限集合 $\{y_1, y_2, \dots, y_L\}$ とする. 以降, 前提 A' と 2.2.1 で定義した確信度付きシングルトン形式ルールの群 R_{ki} が与えられた時の, 直接確信度による Zadeh, Baldwin, 塚本の推論法による結論を, それぞれ $ZC_{ki}, BC_{ki}, TC_{ki}$, 間接確信度による Zadeh, Baldwin, 塚本の推論法による結論を, それぞれ $IZC_k, IBC_{ki}, I_dTC_k \quad (d = 1, 2, 3)$ とする. また, 前提 A' と R_{ki} から確信度を取り去ったルール H_{ki} が与えられたときの, Zadeh, Baldwin, 塚本の推論法による結論を, $ZB_{ki}, BB_{ki}, TB_{ki}$ とする. 式 (2.1)–(2.6) および (2.9)–(2.13) より, 各方式による $y_l \in Y$ に対するメンバシップ値は, 以下の式で与えられる.

$$\mu_{ZC_{ki}}(y_l) = \sup_{x \in X^n} \mu_{A'}(x) * I(\mu_{A_i}(x), W_{ki}\delta_{kl}) \quad (2.23)$$

$$\mu_{BC_{ki}}(y_l) = \sup_{a \in [0, 1]} \tau_{A_i}(a) * I(a, W_{ki}\delta_{kl}) \quad (2.24)$$

$$\mu_{TC_{ki}}(y_l) = \sup_{\substack{(a, c) \in [0, 1]^2 \\ I(a, W_{ki}\delta_{kl}) = c}} \tau_{A_i}(a) * \tau(c) \quad (2.25)$$

$$\mu_{IZC_{ki}}(y_l) = \sup_{x \in X^n} \mu_{A'}(x) * W_{ki} * I(\mu_{A_{ki}}(x), \delta_{kl}) \quad (2.26)$$

$$\mu_{IBC_{ki}}(y_l) = \sup_{a \in [0, 1]} \tau_{A_{ki}}(a) * W_{ki} * I(a, \delta_{kl}) \quad (2.27)$$

$$\mu_{I_dTC_{ki}}(y_l) = \sup_{\substack{(a, c) \in [0, 1]^2 \\ W_{ki} * I(a, \delta_{kl}) = c}} \tau_{A_{ki}}(a) * \tau_{W_{ki}}^d(c) \quad (k = 1, \dots, L, i = 1, \dots, m_k) \quad (2.28)$$

ここで, δ_{ki} はクロネッカーのデルタである. また, τ_{A_i} は式 (2.2) で定義される, 前提 A' に対する命題 “ x is A_{ki} ” のファジィ真理値である.

2.2.1 において, R_{ki} は合計 $D = \sum_{k=1}^L m_k$ 個与えられているので, 合計 D 個の Modus Ponense の結論が与えられる. 各 R_k の Modus Ponense の結論を $C_{ki} \quad (k = 1, \dots, L, i = 1, \dots, m_k)$ とすると, これ

らの結論は、 (2.7), (2.8) により 1つの結論 C_{\max} , もしくは $C_{\text{sum}}(\in F(Y))$ に合成される.

$$\mu_{C_{\max}}(y) = \max_{\substack{k=1, \dots, L \\ i=1, \dots, m_k}} \mu_{C_{ki}}(y) \quad (\forall y \in Y) \quad (2.29)$$

$$\mu_{C_{\text{sum}}}(y) = \sum_{k=1}^L \left(\sum_{i=1}^{m_k} \mu_{C_{ki}}(y) \right) \quad (\forall y \in Y) \quad (2.30)$$

今, R_{ki} の特殊な場合として, 従来形式のルール群 $\{H_i\}_{i=1}^m$ から導かれる以下の数値確信度付きシングルトン形式のルールの群

$$R_{ki}: \text{If } x_1 \text{ is } A_{i1} \text{ and } \dots \text{ and } x_m \text{ is } A_{im}, \text{ Then } y \text{ is } y_k \text{ with } W_{ki} = \mu_{B_i}(y_k) \\ (k = 1, \dots, L, i = 1, \dots, m)$$

を考慮し, Fig. 2.3 に示されるように, このシングルトン形式ルールは, 各 H_i をその後件部ファジィ集合 B_i の各要素 y での値ごとに分解して得られるものである.

また, $C_{\max}^{(i)}, C_{\text{sum}}^{(i)} \in F(Y)$ を以下の式で定義する.

$$\mu_{C_{\max}^{(i)}}(y) = \max_{k=1, \dots, L} \mu_{C_{ki}}(y) \quad (\forall y \in Y) \quad (2.31)$$

$$\mu_{C_{\text{sum}}^{(i)}}(y) = \sum_{k=1}^L \mu_{C_{ki}}(y) \quad (\forall y \in Y) \quad (2.32)$$

式 (2.29), (2.30) より,

$$\mu_{C_{\max}}(y) = \max_{i=1, \dots, m} \mu_{C_{\max}^{(i)}}(y) \quad (\forall y \in Y) \quad (2.33)$$

$$\mu_{C_{\text{sum}}}(y) = \sum_{i=1}^m \mu_{C_{\text{sum}}^{(i)}}(y) \quad (\forall y \in Y) \quad (2.34)$$

なれば,

以下の定理が導かれる.

定理 7

1. $I(a, 0) = I(a, b)$ ($\forall a, b \in [0, 1]$) ならば,

$$C_k = C_k \quad (k = 1, \dots, L, i = 1, \dots, m) \text{ の } \forall \text{ , } \cup B = C_{\max}^{(i)} (i = 1, \dots, m),$$

$$C_k = BC_k \quad (k = 1, \dots, L, i = 1, \dots, m) \text{ の } \forall \text{ , } \cup B = C_{\max}^{(i)} (i = 1, \dots, m).$$




図 2.3: 従来型ルールの数値確信度付きシングルトン型ルールへの分解

2. (i) $I(a, 0) = 0$ ($\forall a > 0$) かつ $\mu_{A_i}(x) > 0$ ($\forall x \in X^n$)

または,

(ii) $I(a, 0) = 0$ ($\forall a$)

ならば,

$$C_{ki} = ZC_{ki} \quad (k = 1, \dots, L, i = 1, \dots, m) \text{ の時, } \cup B_i = C_{\text{sum}}^{(i)} (i = 1, \dots, m),$$

$$C_{ki} = BC_{ki} \quad (k = 1, \dots, L, i = 1, \dots, m) \text{ の } \forall \text{ , } \cup B_i = C_{\text{sum}}^{(i)} (i = 1, \dots, m).$$

(証明) (2.23), (2.24) および $W_{ki} = \mu_{B_i}(y_k)$ ($\forall k, i$) より,

$$\mu_{ZC_i}(y_i) = \sup_{x \in X^n} \mu_{A_i}(x) * I(\mu_{A_i}(x), \mu_{B_i}(y_i)) = \mu_{ZB_i}(y_i)$$

$$\mu_{B^{(l)}_i}(y_l) = \sup_{a \in [0,1]} \tau_{A_i}(a) * I(a, \mu_{B_i}(y_l)) = \mu_{BB_i}(y_l)$$

これより,

(1) 条件より $I(1, 0) = I(1, \mu_{B_i}(y_l)) \ (\forall r, y)$. よって, (12) より, $k \neq l$ に対して,

$$\begin{aligned} \mu_{ZB_i}(y_l) &= \sup_{x \in X^n} \mu_{A_i}(x) * I(\mu_{A_i}(x), \mu_{B_i}(y_l)) \\ &= \sup_{x \in X^n} \mu_{A_i}(x) * I(\mu_{A_i}(x), 0) = \mu_{ZC_{k_i}}(y_l) \\ \mu_{BB_i}(y_l) &= \sup_{r \in [0,1]} \tau_{A_i}(r) * I(r, \mu_{B_i}(y_l)) \\ &\geq \sup_{r \in [0,1]} \tau_{A_i}(r) * I(r, 0) = \mu_{BC_{k_i}}(y_l) \end{aligned}$$

これより結果の式が導かれる.

(2) 条件 (i)(ii) のいずれかが成り立てば, $k \neq l$ に対して

$$\mu_{ZC_{k_i}}(y_l) = \sup_{x \in X^n} \mu_{A_i}(x) * I(\mu_{A_i}(x), 0) = 0$$

また, 条件 (1) の時, τ_{A_i} の定義より $\tau_{A_i}(0) = 0$. よって, 条件 (i)(ii) のいずれかが成り立てば, $k \neq l$ に対し

$$\mu_{BC_{k_i}}(y_l) = \sup_{r \in [0,1]} \tau_{A_i}(r) * I(r, 0) = 0$$

これより結果の式が導かれる.

(証明終)

定理 1, 定理 2 系 1 より, 以下の系が導かれる.

系 1 以下の条件が成立すれば, 従来形式のルール群 $\{H_i\}_{i=1}^m$ に対する Zadeh, Baldwin, 塚本の推論法の * \max 合成による結論と, $\{H_i\}_{i=1}^m$ から得られる確信度付きシングルトン形式のルール群 $\{R_{ki}\}_{k=1}^L, \{R_{ki}\}_{i=1}^m$ に対する直接・間接確信度の Zadeh, Baldwin, 塚本の推論法の * \max 合成による結論とは, すべて一致する.

1. * が左連続
2. $I(a, 0) = I(a, b) \ (\forall a, b \in [0, 1])$
3. $I(1, b) = I(a, b) \ (\forall a, b)$
4. $I(1, b) = b \ (\forall b \in [0, 1])$
5. $\tau_1 = \tau_2 = \tau_{True}$

系 2 以下の条件が成立すれば, 従来形式のルール群 $\{H_i\}_{i=1}^m$ に対する Zadeh, Baldwin, 塚本の推論法の * 加算合成による結論と, $\{H_i\}_{i=1}^m$ から得られる確信度付きシングルトン形式のルール群 $\{R_k\}_{k=1}^L, \{R_{ki}\}_{i=1}^m$ に対する直接確信度の Zadeh, Baldwin, 塚本の推論法の * 加算合成による結論とは, すべて一致する.

1. * が左連続
2. (i) $I(a, 0) = 0 \ (\forall a > 0)$ かつ $\mu_{A_i}(x) > 0 \ (\forall x \in X)$
または,
(ii) $I(a, 0) = 0 \ (\forall a)$
3. $I(1, b) \leq I(a, b) \ (\forall a, b)$
4. $I(1, b) = b \ (\forall b \in [0, 1])$
5. $\tau_1 = \tau_2 = \tau_{True}$

また, 定理 6 系 3 より, 以下の系が導かれる.

系 3 * が左連続, $\tau_1 = \tau_2 = \tau_{True}$, かつ $I(a, b) = a * b \ (\forall a, b \in [0, 1])$ ならば,

1. 従来形式のルール群 $\{H_i\}_{i=1}^m$ に対する Zadeh, Baldwin, 塚本の推論法の * \max 合成による結論と, $\{H_i\}_{i=1}^m$ から得られる確信度付きシングルトン形式のルール群 $\{R_{ki}\}_{k=1}^L, \{R_{ki}\}_{i=1}^m$ に対する直接・間接確信度の Zadeh, Baldwin, 塚本の推論法の * \max 合成による結論とは, すべて一致する.
2. 従来形式のルール群 $\{H_i\}_{i=1}^m$ に対する Zadeh, Baldwin, 塚本の推論法の * 加算合成による結論と, $\{H_i\}_{i=1}^m$ から得られる確信度付きシングルトン形式のルール群 $\{R_{ki}\}_{k=1}^L, \{R_{ki}\}_{i=1}^m$ に対する直接・間接確信度の Zadeh, Baldwin, 塚本の推論法の * 加算合成による結論とは, すべて一致する.

注 3 系 1 の条件が満たされていても, 系 3 の条件が満たされていなければ, 直接確信度による推論結果と間接確信度による推論結果は必ずしも一致しない.

例えば, 今, $L = 2, n = 1, X = [0, 1], m = 1$ の場合で, ルール H_1 において

$$\mu_{A_1}(x) = \begin{cases} 1 & (x \in [0, 1)) \\ 0 & (x = 1) \end{cases}, \quad \mu_{B_1}(y_1) = p, \quad \mu_{B_1}(y_2) = q$$

とする. $\tau_1 = \min, I(a, b) = \min((1 - a) * b, 1)$ の時, 前掲 $\lambda'(\mu_{A_1}(x) * \mu_{B_1}(y)) = \lambda$, $\lambda = \max(p, q)$

ならば,

$$\mu_{ZB_1}(y_1) = \mu_{ZB_1}(y_2) = u$$

$$\mu_{ZC'_{11}}(y_1) = \mu_{ZC'_{11}}(y_2) = v$$

$$\mu_{ZC'_{21}}(y_1) = \mu_{ZC'_{21}}(y_2) = u$$

であり, C'_{11} と C'_{21} の max 合成による結論は B_1 と一致するが,

$$\mu_{IZC'_{11}}(y_1) = \mu_{IZC'_{11}}(y_2) = p$$

$$\mu_{IZC'_{21}}(y_1) = \mu_{IZC'_{21}}(y_2) = q$$

となり, max 合成による結論は B_1 とは異なる.

2.5 考察

以上の結果は, I ノルムから連続 (例えば, \min, \times) の結合関数が $I(a, b) = a * b$ で与えられていれば, 従来形式のルール型数値確信度付キーンルトン型ルールは, 推論法に Zadeh, Baldwin, 塚本のいずれの方法を用いても等価であることを示している. つまり, 式 (1.3) のファジイルールが従来型ルールに等価であるという意味で, 知識表現の形式として一般性を有していることを示しており, その計算処理は Zadeh, Baldwin, 塚本のいずれの推論法, 本章で与えた数値確信度のいずれの解釈にも依存しない.

以降の第3章, 第4章, 第5章では, この形式のルールに基づいて適応的な知識抽出を行う. とくに, 推論の計算処理の簡便化を考慮して, 積 \times を I ノルム, $I(a, b) = a * b$ を結合関数とした Zadeh の直接法 (直接確信度による加算合成に基づく推論処理を用いる. 式 (2.23), (2.30) より, クリスフ入力 $I = (I_1, \dots, I_n) \in \mathbf{R}^n$ に対して, ルール式 (1.3) の出力メンバシップ関数 P_I は,

$$P_I(C) = \sum_{k=1}^{L_I} \omega_k \left(\prod_{i=1}^n F_{k_i}(I_i) \right) \quad (2.35)$$

$$\sum_{k=1}^m \omega_k \exp \left(-\frac{1}{2} \sum_{i=1}^n \frac{(\mu_{C_i} - I_i)^2}{\sigma_{C_i}^2} \right) \quad (k = 1, \dots, L)$$

となる. ここで, ω_k の数値は, 与えられた入力 I に対する出力 C の C である割合を示している.

次章においても触れることであるが, この推論処理はガウス基底を用いた Radial Basis Function(RBF)と同じものであり, RBF の全体の関数空間が連続関数の空間の中で密 [24], つまり, 任意の連続関数を任意の精度で近似可能であるという意味でも, 式 (1.3), (1.4) で表されるファジィ推論規則群の一般性を表していると考えられる. ただし, 第3章, 第4章, 第5章ではこのメンバシップ関数を正規化し得られるメンバシップ関数

$$P'_I(C_k) = \frac{P_I(C_k)}{\sum_{d=1}^L P_I(C_d)} \quad (2.36)$$

を最終出力として用いる.

第3章 Fuzzy Self-Organizing Mapを用いた 適応的ファジィルール抽出

3.1 はじめに

ファジィルールを適応的に抽出するための方式として、ニューラルネットワーク、とくに Kohonen の Self-Organizing Map (自己組織化写像, 以降 SOM と略称) を用いた入出力空間のクラスタリングが考えられる [14]. SOM を基本とするファジィクラスタリングの手法は既に幾つか提案されている [3, 5, 34]. [3] で提案されている “Fuzzy Kohonen Clustering Network” (以降, FKCN と略称) は Fuzzy c-means アルゴリズムの拡張であり, SOM の競合学習における勝利ノードの概念をファジィ化したものと考えられる. また, [5] においては, FKCN を用いたファジィ競合学習の一般化がなされている. [34] においては, シンシフ Then ルールの前件部 1 つのメンバシップ関数を 1 つの SOM で表し, 競合学習によるクラスタリング終了後のノードの入力に対するマッチ度をメンバシップ値としている.

しかし, [3-5] のネットワークでは入力空間をカバーするファジィ集合の明示的な形式が与えられておらず, シンシフ Then ルールの構造も持っていない. また, [34] のネットワークでは 1 つのメンバシップ関数の表現に 1 つの SOM が必要であり, ルールおよびその前件部の数が増える分だけネットワークが必要となる.

上述の弱点を克服し, 式 (1.3), (1.4) で示されるファジィ推論規則群の前件部のファジィメンバシップ関数の調整を行うために, 本章では, SOM にファジィメンバシップ関数の処理部を導入し, 入力空間の適応的クラスタリングを行うニューロモデル “Fuzzy Self-Organizing Map” (ファジィ自己組織化写像, 以降 FSOM と略称), および競合学習に基づくその推論規則を与える. そして, この FSOM を基に, 式 (1.3), (1.4) で示されるファジィ推論規則群を表現する “Fuzzy Inference Network” (ファジィ推論

ネットワーク, 以降 FIN と略称) を構成し, 式 (1.1) の入出力データからファジィ推論規則を適応的に抽出する手法を与える.

3.2 SOM と FSOM

3.2.1 SOM と競合学習

オリジナルの SOM は, 一定の分布に従う入力ベクトルに対し, 競合学習によりその分布を近似するニューラルネットである [13]. 図 3.1 では, n 個の入力ノードと m 個の出力ノードを持ち, j 番目の入力




図 3.1: SOM の構成

ノードから i 番目の出力ノードに対し, 実数値 ω_{ij} が結合係数として与えられている. また, 出力ノードの集合は空間的に配置され, 各ノードは空間における近傍を持つ. 図 3.1 では, 出力ノードは 2 次元平面上に配置され, 平面上の近傍 $NEIB(i)$ ($i = 1, \dots, m$) を持つ. n 次元入力ベクトル $I = (I_1, \dots, I_n) \in \mathbf{R}^n$ に対して, SOM の各出力ノードにおいてその対応する結合係数ベクトル $\omega_i = (\omega_{i1}, \dots, \omega_{in}) \in \mathbf{R}^n$ のマッチ度が計算され, 最もマッチ度の高い出力ノードが決定される. 具体的には,

$$\|\omega_i - I\| = \min(\|\omega_i - I\|; i = 1, \dots, m)$$

を満たす i 番目のノードを競合における勝利ノードとする. ここで, $\|\cdot\|$ は n 次元ユークリッド距離としている. したがって, この勝利ノード i とその近傍 $NEIB(i)$ の出力ノードに対して, 以下のよう

¹ 以降 [17, 16] 以降の参考文献.

結合係数を更新する。

$$\Delta\omega_{ij} = \begin{cases} \gamma(I_j - \omega_{ij}) & (i \in NEIB(i_0)) \\ 0 & (\text{otherwise}) \end{cases} \quad (j = 1, \dots, n)$$

ここで、 γ は学習係数である。この更新則は、 $i \in NEIB(i_0)$ に対する評価関数

$$J(I, \omega_i) = \frac{1}{2}(\omega_{ij} - I_j)^2$$

に対する最急降下法、つまりベクトル I とのマッチ度を高める方向へベクトル ω_i を更新している。また、各近傍 $NEIB(i)$ を学習が進むにつれ縮小することにより、良好な学習結果が得られる。

この処理を入力かたがえられる度に繰り返すことにより、SOM は多次元ベクトル空間における入力ベクトルの分布を教師信号無しにクラスタリングする。つまり、入力 I に対して競合で勝利するノードのラベルか I の属するクラスタのラベルとなる。

また、FKCN などのファジィ競合学習ネットワークでは、SOM の競合学習における勝利ノードの近傍の概念をフーシィ化することによりクラスタリングを行う。つまり、各ノードごとに学習係数 γ_i を

$$\gamma_i = u_i^m, \quad u_i = \frac{1}{\sum_j \left(\frac{\|\omega_i - I\|}{\|\omega_j - I\|} \right)^{\frac{m}{m-1}}}$$

を設定することにより、入力 I とのマッチ度に応じて係数更新の度合いを決定する。また、乗数 m を 1 に近づけることにより、SOM の近傍縮小と同じ効果を得る。

3.2.2 FSOM

本稿のFSOMは、SOMの結合係数をフーシィ化したものであり、基本的にSOMと同じクリスプな競合学習を用いて入力空間内フーシィクラスタリングを行う。SOMおよびFKCNが入力データにおけるクラスタの代表点の位置のみを学習するのに対し、FSOMは代表点の位置と同時にその周りの分散も学習する。図3.2にFSOMの基本構成を示す。

本構成では、FSOMは n 個の入力ノードと m 個の出力ノードを持つ。基本的なネットワーク構造はSOMと同じであるが、 j 番目の入力ノード、 i 番目の出力ノードに対し、1次元のガウス型フーシィ




図 3.2: FSOM の構成

メンバシップ関数

$$F_{ij}(x) = \exp\left(-\frac{1}{2} \frac{(\mu_{ij} - x)^2}{\sigma_{ij}^2}\right) \quad (i = 1, \dots, m, j = 1, \dots, n) \quad (3.1)$$

を結合係数として持つ。 n 次元入力ベクトル $I = (I_1, \dots, I_n) \in \mathbf{R}^n$ に対し、各出力ノードの出力は I の各成分に対する式 (3.1) で表されるファジィメンバシップ関数 F_{ij} の出力の積

$$\begin{aligned} F_i(I) &= \prod_j F_{ij}(I_j) \\ &= \exp\left(-\frac{1}{2} \sum_j \frac{(\mu_{ij} - I_j)^2}{\sigma_{ij}^2}\right) \quad (i = 1, \dots, m) \end{aligned} \quad (3.2)$$

で表される。 μ_i は $\mu_i = (\mu_{i1}, \dots, \mu_{in})$ を中心、 $\sigma_i = (\sigma_{i1}, \dots, \sigma_{in})$ を各座標での幅とするガウス型フーシィメンバシップ関数であり、入力ベクトル I に対する各ノードの出力を、 F_i をメンバシップ関数として n 次元ユークリッド空間上のフーシィ集合への I の所属度と見なすことが出来る。また、SOM と同

様に出力ノードは空間構造を持つ。

SOM の出力ノードの競合においては、入力ベクトルと結合係数ベクトルとの距離の最も近いノードが勝利ノードとされている。これに対し、FSOM における競合はノードに対応するファジィ集合への帰属度を用いて勝利ノードを決定する。具体的には、入力ベクトル $I = (I_1, \dots, I_n)$ に対し、

$$F_{i_0}(I) = \max(F_i(I) : i = 1, \dots, m) \quad (3.3)$$

となる i_0 番目の出力ノードを勝利ノードとし、2次元出力ノード空間における勝利ノード i_0 の近傍 $NEIB(i_0)$ に属するノード i に対してのみ、以下の評価関数を最急降下法により最小化するように中心ベクトル μ_i と分散ベクトル σ_i を更新する。

$$E_1(I, \mu_i) = \frac{1}{2} \sum_j (\mu_{ij} - I_j)^2 \quad (3.4)$$

$$E_2(I, \sigma_i) = \frac{1}{2} \sum_j (\sigma_{ij}^2 - (\mu_{ij} - I_j)^2) \quad (3.5)$$

従って、更新則は以下のように定められる。

$$\Delta \mu_i = \begin{cases} \gamma \frac{\partial E_1(I, \mu_i)}{\partial \mu_{ij}} = \gamma (I_j - \mu_{ij}) & (i \in NEIB(i_0)) \\ 0 & (\text{otherwise}) \end{cases} \quad (3.6)$$

$$\Delta \sigma_{ij} = \begin{cases} \gamma \frac{\partial E_2(I, \sigma_i)}{\partial \sigma_{ij}} = 2\gamma \sigma_{ij} ((\mu_{ij} - I_j)^2 - \sigma_{ij}^2) & (i \in NEIB(i_0)) \\ 0 & (\text{otherwise}) \end{cases} \quad (3.7)$$

($j = 1, \dots, n$)

ここで、(3.4) の評価関数は SOM の式 (2.1) に用いられたのと同じもの、つまりガウス型ファジィメンバシップ関数 F_i の中心 μ_i と入力ベクトル I とのマッチングを表す。(3.5) の評価関数は F_i の分散 σ_i と I の中心 μ_i からの実際の分散とのマッチングを表している。つまり、この更新則は、入力データのファジィ集合の品質が高くなるようにメンバシップ関数のパラメータを調整することに対応する。また、SOM と同様に FSOM においても、学習の初期にはノードの近傍を大きめにとり、学習が進むにつれて近傍を縮小する。

3.2.3 FSOM におけるファジィ競合学習の導入

第 3.2.2 章の FSOM の学習則におけるノードの競合は、元となった SOM におけるベクトル間距離による競合をメンバシップ関数の出力値に置き換えたものであり、出力ノードの集合に 2次元平面の構造を導入し、各ノードに 2次元平面上のクリスプなノード近傍を導入して用いている。本節ではもう 1つの学習則として、第 3.2.1 章でも触れたファジィ競合学習 [5] の概念に基づき、入力データに対する各ノードの出力の大きさに応じたファジィ近傍を用いた学習則を与える。

ファジィ競合学習ネットワークでは、Fuzzy c-Means クラスタリングの考えに基づき SOM の競合学習における勝利ノードの近傍の概念をファジィ化することによりクラスタリングを行う。この方式では、入力 I に対する各代表点ベクトルの差異の重み付き評価関数

$$E(I, \mu, f) = \frac{1}{2} \sum_i f_i^h \sum_j (\mu_{ij} - I_j)^2 \quad (f_i > 0) \quad (3.8)$$

を制約条件 $\sum_i f_i = 1$ の下で最小化する。各重み f_i ($i = 1, \dots, m$) は、入力 I が μ_i の代弁するクラスに帰属する度合を表す。ここで、乗数 h は 1 を超える実数である。この評価関数に制約条件 $\sum_i f_i = 1$ を加えたラグランジュ乗数法による全体の評価関数

$$L(I, \mu, f, \lambda) = E(I, \mu, f) + \lambda \left(\sum_i f_i - 1 \right) \quad (3.9)$$

に対して、 f_i を固定し、最急降下法により μ_{ij} の更新則

$$\Delta \mu_{ij} = -\gamma \frac{\partial E}{\partial \mu_{ij}} = \gamma f_i^h (I_j - \mu_{ij}) \quad (i = 1, \dots, m, j = 1, \dots, n) \quad (3.10)$$

を得る。また、 f_i は、 μ を固定し、 $\frac{\partial L}{\partial f_i} = 0$ ($i = 1, \dots, m$)、 $\frac{\partial L}{\partial \lambda} = 0$ とすることにより、

$$\begin{aligned} \lambda \left(\sum_i f_i - 1 \right) &= 0 \\ h f_i^{h-1} \sum_j (\mu_{ij} - I_j)^2 + \lambda &= 0 \\ f_i &= -\frac{\lambda}{h} \frac{1}{(\sum_j (\mu_{ij} - I_j)^2)^{\frac{1}{h-1}}} = \frac{\left(\sum_j (\mu_{ij} - I_j)^2 \right)^{\frac{1}{h-1}}}{\sum_d \left(\sum_j (\mu_{dj} - I_j)^2 \right)^{\frac{1}{h-1}}} \quad (i = 1, \dots, m) \end{aligned} \quad (3.11)$$

と定められる。式 (3.10)、(3.11) に示されるように、代表点 μ_i が入力 I に近いほど f_i は大きくなり、 μ_i が更新されるとステップ幅が大きくなる。元々 SOM においては、ノード集合の間における近傍関係、

して、その空間での近傍への帰属に基づいて代表点の更新幅を決めていたのに対して、この学習則では、ノード集合の空間構造は考えず、入力に対する代表点の近さの度合いに応じて代表点の更新幅を調整する、いわばフジィ近傍を実現している。さらに、学習が進むにつれて $h \rightarrow 1$ とすることにより $f_i \rightarrow 0$ or 1 となるため、クリスプな場合の近傍縮小と同じ効果を得る。しかし、この学習則は近傍設定に FSOM 自身から得られるメンバーシップ関数の出力値 $F_i(I)$ を全く考慮していない。

一方、ガウシアンクラスタリング [16] では、ファジィ競合型ネットワークと同様の評価関数にエン트로ピー項を導入した

$$E(I, \mu, f) = \frac{1}{\alpha} \sum_i f_i \sum_j (\mu_{ij} - I_j)^2 + \sum_i f_i \log(f_i) \quad (f_i > 0) \quad (3.12)$$

を評価関数とし、制約条件 $\sum_i f_i = 1$ の下で最小化することにより代表点 μ_i および重み f_i の学習則を得る。式 (3.9) のラグランシ乗数法による全体の評価関数を考え、 μ を固定して $\frac{\partial \hat{E}}{\partial f_i} = 0$ ($i = 1, \dots, m$)、 $\frac{\partial \hat{E}}{\partial f_i} = 0$ とすることにより、

$$\begin{aligned} & \frac{1}{\alpha} \sum_j (\mu_{ij} - I_j)^2 + \log(f_i) + 1 + \lambda = 0 \\ f_i &= \exp(-1 - \lambda) \exp\left(-\frac{1}{\alpha} \sum_j (\mu_{ij} - I_j)^2\right) \\ &= \frac{\exp\left(-\frac{1}{\alpha} \sum_j (\mu_{ij} - I_j)^2\right)}{\sum_d \exp\left(-\frac{1}{\alpha} \sum_j (\mu_{dj} - I_j)^2\right)} \quad (i = 1, \dots, m) \end{aligned} \quad (3.13)$$

と定められる。

FSOM のファジィ競合学習においては、上記 2 つのクラスタリング手法の考え方を融合し、分散の影響を取り入れた

$$I(I, \mu, f) = \frac{1}{2} \sum_i f_i \sum_j \frac{(\mu_{ij} - I_j)^2}{\sigma_{ij}^2} + \sum_i f_i \log(f_i^h) \quad (f_i > 0) \quad (3.14)$$

を評価関数とし、制約条件 $\sum_i f_i = 1$ の下で最小化する。この場合、ラグランシ乗数法による全体の評価関数

$$I(I, \mu, f, \lambda) = I(I, \mu, \sigma, f) + \lambda \left(\sum_i f_i - 1 \right)^2 \quad (3.15)$$

に対する最急降下法により、 μ_{ij} の更新則

$$\Delta \mu_{ij} = -\gamma \frac{\partial E}{\partial \mu_{ij}} = -\gamma f_i^h \frac{I_j - \mu_{ij}}{\sigma_{ij}^2} \quad (i = 1, \dots, m, j = 1, \dots, n) \quad (3.16)$$

を得る。また、 μ を固定して $\frac{\partial \hat{E}}{\partial f_i} = 0$ ($i = 1, \dots, m$)、 $\frac{\partial \hat{E}}{\partial \lambda} = 0$ とすることにより、

$$\begin{aligned} & \lambda \left(\sum_i f_i - 1 \right)^2 = 0 \\ & \frac{h}{2} f_i^{h-1} \sum_j \frac{(\mu_{ij} - I_j)^2}{\sigma_{ij}^2} + h f_i^{h-1} \log(f_i^h) + h f_i^{h-1} + 2\lambda \left(\sum_i f_i - 1 \right) = 0 \\ & \frac{1}{2} \sum_j \frac{(\mu_{ij} - I_j)^2}{\sigma_{ij}^2} + \log(f_i^h) + 1 = 0 \end{aligned}$$

$$f_i^h = \epsilon^{-1} \exp\left(-\frac{1}{2} \sum_j \frac{(\mu_{ij} - I_j)^2}{\sigma_{ij}^2}\right) = \epsilon^{-1} F_i(I) \quad (3.17)$$

$$f_i = \epsilon^{-\frac{1}{h}} F_i(I)^{\frac{1}{h}} = \frac{F_i(I)^{\frac{1}{h}}}{\sum_d F_d(I)^{\frac{1}{h}}} \quad (i = 1, \dots, m) \quad (3.18)$$

が得られる。式 (3.16)、(3.18) の学習則は、ファジィメンバーシップ関数の出力値 $I_i(I)$ を考慮したのとなっている。学習が進むにつれて $h \rightarrow 0$ とすることにより $f_i \rightarrow 0$ or 1 となるが、式 (3.17) より、 f_i^h は $F_i(I)$ の 1 次関数であるため、ファジィ近傍の縮小進行が遅い。そのため、 μ_{ij} に対しては以下の単純化された学習則

$$\Delta \mu_{ij} = \gamma f_i (I_j - \mu_{ij}) \quad (i = 1, \dots, m, j = 1, \dots, n) \quad (3.19)$$

を用いる。これは、式 (3.10) のファジィ競合学習の簡略版でもある。 σ_{ij} に対しては、単純に

$$E(I, \sigma) = \frac{1}{2} \sum_i f_i \sum_j (\sigma_{ij}^2 - (\mu_{ij} - I_j)^2)^2 \quad (3.20)$$

を評価関数とし、最急降下法による

$$\Delta \sigma_{ij} = 2\gamma f_i \sigma_{ij} ((\mu_{ij} - I_j)^2 - \sigma_{ij}^2) \quad (i = 1, \dots, m, j = 1, \dots, n) \quad (3.21)$$

を学習則とする。

3.3 FINの導入によるルール抽出

本節では、3.2.3 で述べた FSOM を基に、式 (1.3), (1.4) で示されるファジィ推論規則群を表現するニューラルネットワーク FIN を構成し、それを用いた適応的ファジィ推論規則抽出の方式を与える。また、FIN の構造が RBF と類似していることを踏まえて、RBF によるファジィ推論規則抽出の方式との比較検討を行う。さらに、ニューラルネットワークによる方式と対比して、遺伝的アルゴリズムによるファジィ推論規則抽出の方式との比較検討も行う。

3.3.1 FIN

FIN は多入力 1 出力、3 層構造の Feedforward 型ニューラルネットワークであり、上位層は FSOM の構造を有する。入力ノード数は、式 (1.3) の推論規則の前件部の入力数と同じ n 、中間ノード数は、後件部が同じシングルトン形式を持つ規則の数 m である。1 つの FIN は、式 (1.3) に示される合計 $m \times L$ 個のファシールールから、後件部が同じシングルトン形式を持つ m 個のルール群をまとめて表現する。図 3.3(a) に、推論規則と FIN の構造との関係を示す。図 3.3 において、上位層の FSOM 部は各ルール前件部に対応し、下層は後件部と数値確信度に対応する。

FIN と式 (1.3), (1.4) で示されるファジィ推論規則の対応関係は、以下のように構成される。式 (1.3) の推論規則群のうち、後件部が同じシングルトン構造を持つ m 個の規則

$$\text{If } I_1 \text{ is } F_{k11} \text{ and } I_2 \text{ is } F_{k12} \text{ and } \dots \text{ and } I_n \text{ is } F_{k1n}, \text{ Then } c \text{ is } C_k \text{ with weight } \omega_{k1} \quad (3.22)$$

$$\sum_i \omega_{ki} = 1 \quad (i = 1, \dots, m)$$

に対して、1 つの FIN に対応する。この FIN (以降、 FIN_k と略称) は、 F_{kij} を i 番目の中間ノードと j 番目の入力ノード間の結合係数として持つ。また、各規則の数値確信度 ω_k を i 番目の中間ノードと出力ノード間の数値結合係数として持つ。式 (1.3) の推論規則群において、異なるシングルトン形式の後件部は合計 L 個存在するので、規則群全体に対して合計 L 個の FIN $\{FIN_1, \dots, FIN_L\}$ に対応する。入力ベクトル $I = (I_1, \dots, I_n)$ に対する FIN_k の中間ノードの出力、つまり FSOM の出力




図 3.3: FIN の構造と推論規則群との関係

ノードにおける値

$$F_{ki}(I) = \prod_j F_{kij}(I_j) \quad (k = 1, \dots, L, i = 1, \dots, m) \quad (3.23)$$

は、各ルール前件部に対する適合度を表す。 FIN_k の出力 P_k は、

$$P_k(I) = \sum_i \omega_{ki} F_{ki}(I) \quad (k = 1, \dots, L) \quad (3.24)$$

のように、FSOM によって得られた各ルール前件部の適合度の重みとの積和によって得られる。この出力値は、式 (1.3) のファシールール群の入力 I に対する直接法による推論結果の出力メンバーシップ関数値 (2.35) に他ならず、入力 I に対する出力値が C_k である可能性を示している。また、最終的な推論

結果として、 FIV_k の出力 P_k ($k = 1, \dots, L$) を、

$$P'_k(I) = \frac{P_k(I)}{\sum_d P_d(I)} \quad (k = 1, \dots, L) \quad (3.25)$$

の形で正規化する。これは式 (2.36) で表される値に他ならない。

FIV の FSOM における競合学習によって、入出力データから式 (1.3), (1.4) の推論規則の前件部のハフメータを直接抽出することか可能となる。また、数値確信度 ω_{ki} の学習は、競合学習の過程において、対応する中間層ノードがどれだけデータに対して反応したかを記録する反応頻度ハフメータ W_{ki} ($k = 1, \dots, L, i = 1, \dots, m$) を用意しておき、学習終了時に正規化することによって行う。式 (1.1) の入出力データ集合 S からのファジィ推論規則抽出の手順は、以下のように行なう。

(0): 式 (1.1) の入出力データ集合 S に対して、式 (1.3) で与えられるファジィルール群に対応する FIV の出力値 C_k ごとに合計 L 個用意し、前件部メンバシップ関数のハフメータ μ_{kij}, σ_{kij} をランダムに初期化する。また、反応頻度ハフメータ W_k を全て 0 に設定する。

(1): 式 (1.2) の S の出力値による分割 $\{S_k : k = 1, \dots, L\}$ に対して、 $S^{(l)} \in S_k$ の入力データ部分の数値ベクトル $a_l = (a_{l1}, a_{l2}, \dots, a_{ln})$ を FIV_k に入力として与える。

(注: FIV_k に入力されているのは、 S_k に属するデータのみであり、 C_k 以外の出力値を持つ入出力データは無視する。)

(2): FIV_k の FSOM において、上記 a_l に対して第 3.2.2 章の競合学習、もしくは 3.2.3 のファジィ競合学習のアルゴリズムにより、ファジィメンバシップ関数のハフメータ μ_{kij}, σ_{kij} を更新する。

(3): 第 3.2.2 章の学習アルゴリズムの場合、(2) の出力ノードの競合における勝利ノードを i_0 とすると、反応頻度ハフメータ W_k を以下のように更新する。

$$\Delta W_k = \begin{cases} 1 & (j = i_0) \\ 0 & (\text{otherwise}) \end{cases} \quad (k = 1, \dots, L, i = 1, \dots, m) \quad (3.26)$$

第 3.2.3 章のファジィ競合学習アルゴリズムの場合、反応頻度ハフメータ W_{ki} を以下のように更新する。

$$\Delta W_{ki} = F(a_i) \quad (k = 1, \dots, L, i = 1, \dots, m) \quad (3.27)$$

(4): 各 $S^{(l)}$ に対して 1-3 を行い、それを指定回数繰り返す。

(5): W_{ki} を

$$\omega_{ki} = \frac{W_{ki}}{\sum_d W_{kd}} \quad (l = 1, \dots, L, i = 1, \dots, m) \quad (3.28)$$

の形で正規化し、ファジィルールの確信度 ω_k を決定する。

FIV によるルール抽出の手法を、図 3.4(a) に示す。

FIV によるルール抽出の利点としては、主に以下の 2 点が挙げられる。

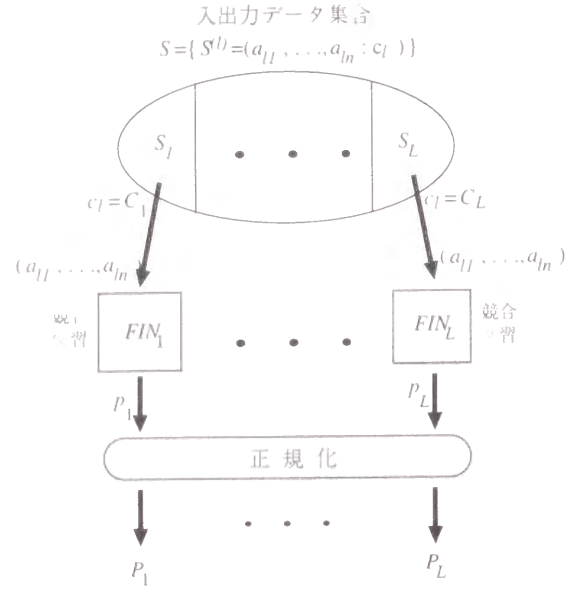
1. FSOM を用いた入力空間のクラスタリングにより、数値データの取り扱いと適応的なルール抽出、および FIV による推論が同時に可能となる。
2. Back Propagation などの入出力自乗誤差学習則を基本とする Feedforward 型ネットワークは、1 つのネットワークに総ての入出力データを学習サンプルとして与える必要がある。 FIV では入出力データ集合の出力値による分割と FSOM の教師無し学習により、1 つの FIV にすべての入出力データを与える必要はなく、学習処理も低減される。

逆に、欠点としては、式 (1.3) にあるように全ての属性値を評価する必要があるため、ID3 のように出力値の識別に意味のある属性のみを選択するルール抽出が出来ないことである。この欠点は FIV による方式のみならず、後に示す GA を用いる方式についても、免れることである。


3.3.2 Radial Basis Function による方式との比較検討

前章で与えられた FIV の構造は、本能的にガウス基底を用いた Radial Basis Function [24](以降 RBF と略称) と同じものである。そのため、式 (1.3), (1.4) のファジィ推論規則の抽出において、RBF を用いた方式を構成し、前章の FIV を用いた方式と比較検討する必要がある。


RBF による適応的ルール抽出法は、 FIV の場合と同様に、同じシングルトン形式の後件部を持つ m 個の推論規則に対して、 n 個の入力ノード、 m 個の中間ノード、1 個の出力ノードを持つ RBF を 1 つ対応させることにより実現出来る。つまり、 m 個の推論規則に付随する m 個の n 次元ガウス型メンバシップ関数 F_{k1}, \dots, F_{km} をガウス基底とし、 m 個の数値確信度 $\omega_{k1}, \dots, \omega_{km}$ を中間層と出力層間の結合



(a) FINによる入出力データからのルール抽出



(b) RBFによる入出力データからのルール抽出



(c) GAによる入出力データからのルール抽出

図 3.4. FIN, RBF および GA による入出力データからのルール抽出

係数とすることで,

$$o_k(I) = \sum_i \omega_{ki} \exp \left(-\frac{1}{2} \sum_j \frac{(\mu_{kij} - I_j)^2}{\sigma_{kij}^2} \right) \quad (k = 1, \dots, L) \quad (3.29)$$

の形式の RBF を L 個構成する (以降, 出力値 C_k に対応する RBF を RBF_k と略称). また, FIN の場合と同様に, 最終的出力は上記 o_k を正規化した値

$$o'_k(I) = \frac{o_k(I)}{\sum_d o_d(I)} \quad (k = 1, \dots, L) \quad (3.30)$$

とする. 式 (3.29) の出力形式は, 式 (2.35) で示されるルール (1.3) の出力と同じ, つまり FIN の推論出力と全く同じである. このことは, RBF の形式が持つ関数近似能力を, FIN, つまり式 (1.3), (1.4) のファジィ推論規則も有していることを示している.

RBF における学習は, 基本的に入出力自乗誤差に基づいて行われる. そのため, FSOM 層の教師無し学習を用いる FIN とは異なり, 式 (1.1) の入出力データをそのまま用いることは出来ない. そのため, RBF_k に与える教師データを以下のように構成する.

入力: $(a_{l1}, a_{l2}, \dots, a_{ln})$, 教師出力: $T_k(c_l)$

$$T_k(c_l) = \begin{cases} 1.0 & (c_l = C_k) \\ 0.0 & (\text{otherwise}) \end{cases} \quad (k = 1, \dots, L, l = 1, \dots, N) \quad (3.31)$$

各 RBF_k の学習則は, この教師データにおける自乗誤差に係数 ω_{ki} に対する正規化条件を加えたもの

$$Error_k = \frac{1}{2} \sum_l (o_k(a_l) - T_k(c_l))^2 + \left(\sum_i \omega_{ki} - 1 \right)^2 \quad (k = 1, \dots, L) \quad (3.32)$$

に対する最急降下法によって行われる. ω_{ki} の正規化条件は, ファジィルールの重みの正規性を実現するためである.

図 3.4(b) に RBF によるルール抽出の構成を示す. FIN による方式では, 1 つの FIN に与える入出力データはその対応する出力値を持つデータに限定されていたのに対し, RBF による方式では, 1 つの RBF に総ての入出力データを与える必要があり, 学習処理の負荷が L 倍になる欠点がある.

3.3.3 遺伝的アルゴリズムによる方式との比較検討

もう1つの比較検討対象として、最近多くの研究例が報告されている遺伝的アルゴリズム (Genetic Algorithm, 以降 GA と略称) を用いたルール抽出 [40] を取り上げる。この方式は後に第4章、第5章において扱う。本稿でのGAによるフーシイ推論規則抽出の基本手順は以下の通りである。

(0-1): 式(1.3), (1.4)に示す1つのフーシイルールのパラメータ μ_{kij}, σ_{kij} ($j = 1, \dots, n$) をビット列もしくは実数値配列で表現し、1つの個体染色体とする。つまり、1つのルールに1つの個体を対応させる。

(0-2): 同じシングルトン形式の後件部“ c is C_k ”を持つフーシイルールに対応する m 個の個体で1つの集団 (以降 POP_k と略称) を形成し、合計 L 個の集団を作る。

(1): 各 POP_k において独立に選択、交叉、突然変異を行う。つまり、異なる集団間の遺伝子の移動は無いものとする。選択は、個体の評価値および適応度を以下の式(3.33), (3.34)により計算し、ルーレット戦略を用いて行う。

$$\epsilon_{kl} = \sum_i \frac{1}{2} (F_{kl}(a_l) - T_k(c_l))^2 \quad (3.33)$$

$$F_{kl}(a_l) = \exp \left(-\frac{1}{2} \sum_j \frac{(\mu_{kij} - a_{lj})^2}{\sigma_{kij}^2} \right)$$

$$f_{kl} = \max(\epsilon_{kl} : i = 1, \dots, m) - \epsilon_{kl} + sp \cdot \min(\epsilon_{kl} : i = 1, \dots, m) \quad (3.34)$$

$$(k = 1, \dots, L, i = 1, \dots, m)$$

ここで、 $T_k(c_l)$ は式(3.31)で定義されているものとする。式(3.33)は全入出力データに対する個体に対応するフーシイルールの前件部適合度の自乗和である。式(3.34)における sp は選択圧力であり、この値が大きければ、ルーレット選択における個体間の生存確率の差が減少し、評価値の小さい個体も選択において生存しやすくなる。

(2): 各 POP_k において与えられた回数だけ世代交代を行った後、ルールの重みを対応する個体の集団における適応度で正規化

$$w_i = \frac{f_i}{\sum_i f_i} \quad (k = 1, \dots, L, i = 1, \dots, m) \quad (3.35)$$

により定める。得られたルールの入力ベクトル $I = (I_1, \dots, I_n)$ に対する出力は、FIN, RBF と同様に、ルール(1.3)出力

$$O_k(I) = \sum_i \omega_k F_k(I) \quad (k = 1, \dots, L) \quad (3.36)$$

を正規化したもの

$$O'_k(I) = \frac{O_k(I)}{\sum_d O_d(I)} \quad (k = 1, \dots, L) \quad (3.37)$$

とする。

図3.4(c)にGAによるルール抽出の構成を示す。本方式による個体適応度は、ルールの入出力データに対する自乗誤差が低いほど高くなるように定義しており、適応度の計算に総ての入出力データが必要となるため、RBFの場合と同様にルール抽出の負荷がFINに比べて L 倍高い欠点がある。しかし、FINやRBFなどのニューラルネットワークとは異なるGAの性質が、第1章で触れた本稿の目的である動的環境での規則抽出の面で活用される可能性がある。

第3.4章でのシミュレーションでは、Simple GAによる適応的ルール抽出を比較対象とする。ここでは、1つのフーシイルールのパラメータ μ_{kij}, σ_{kij} を各々16ビットの0-1のグレイコードによるビット列で表現し、1直線に並べた $2 \times 16 \times n$ ビットから成る0-1のビット列を1つの個体染色体とする。また、交叉法としては1点交叉、突然変異としてはビット突然変異を採用する。後に第4章、第5章では、進化の対象となるパラメータが実数値であることを踏まえた手法を与える。

3.4 動的環境におけるシミュレーションと評価

FINによる適応型ルール抽出法の有効性を示すシミュレーションとして、入力データの分布が時間的に変化する入出力サンプリングデータを用い、フーシイ推論結果に対する正誤率を評価する実験を行った。なお、本章においては2種類の比較実験を行っている。1つは、FINそのものの有効性を検証するため、第3.3.2章、第3.3.3章で議論したRBF, GAによる方式との比較実験であり、もう1つは、FINにおけるFSOM [3]での第3.2.2章で与えた学習規則と第3.2.3章で与えたフーシイ観測データの優劣を検証するための比較実験である。

3.4.1 他方式との比較実験

本実験では、他の適応的ルール抽出法と比較することにより FIN の有効性を検証するため、第 3.3.2 章、第 3.3.3 章で与えた入出力自乗誤差学習則を基本とする RBF、および同じく入出力自乗誤差を適応度計算に用いた GA と、FIN 方式との間で性能比較を行った。

実験データ

実験データは、3 次元の入力値ベクトルと 3 種類の出力値を持ち (式 (1.1), (1.2) において $n = 3$, $l = 3$)、同じ出力値を持つ入出力データの入力値ベクトルの平均が段階的に変化するものと想定した。また、以下の 3 種類の実験を行った。

- 1: C_1 を出力値に持つ ($S^{(1)}$ に属する) データの入力属性ベクトル平均のみ変化
- 2: C_1 と C_2 を出力値に持つ ($S^{(1)}$ と $S^{(2)}$ に属する) データの入力属性ベクトル平均のみ変化
- 3: すべての入力属性ベクトル平均が変化

表 3.1 および図 3.5 に、各出力値を持つ入出力データの入力値ベクトルの平均の変化を示す。




図 3.5: 実験用入出力データにおける中心の変化

	step 0	step 1	step 2	step 3	step 4
S_1 平均	(2.0, 0.0, 0.0)	(1.5, 0.0, 0.5)	(1.0, 0.0, 1.0)	(0.5, 0.0, 1.5)	(0.0, 0.0, 2.0)
S_2 平均	(0.0, 2.0, 0.0)	(0.5, 1.5, 0.0)	(1.0, 1.0, 0.0)	(1.5, 0.5, 0.0)	(2.0, 0.0, 0.0)
S_3 平均	(2.0, 2.0, 2.0)	(1.5, 2.0, 1.5)	(1.0, 2.0, 1.0)	(0.5, 2.0, 0.5)	(0.0, 2.0, 0.0)

表 3.1: 実験用入出力データにおける中心の変化

実験データは、表 3.1 および図 3.5 に示す各ステップのベクトルを平均とする分散 1 の正規分布に従って発生させた。データ数は、1 つの出力値に対し学習用に 20 個、評価用に 20 個、合計 5 ステップで 60 個の学習データ、60 個の未学習データを用意した ($N = 60$, 各 S_k の要素数=20)。実際の実験では、上記データを $[0, 1]$ 区間に正規化して行なった。本実験データは、中間のステップでは各出力を持つデータの入力ベクトル平均のユークリッド距離がステップの最初および最後に比べて小さいという特徴を持つ。

実験は、各ステップにおける入出力データに対する正答率を評価項目とした。まず、ステップ 0 の初期状態から 60 個のデータを学習、60 個の未学習データに対する正答率を評価した。その後、各ステップの新たな傾向のデータに対して、学習データに対する学習前の正答率、その正答率、未学習データに対する正答率を評価した。ステップ 0 以降では、各方針におけるハフメタの初期値は前ステップにおける学習後の値をそのまま継続した。また、出力 C_k を持つ入出力データに対する正答率を式 (3.25), (3.30), (3.37) により以下で定義する。

FIN 方式 : $P_k^l = 100 \times \sum_{a_l \in S_k} \frac{P_k^l(a_l)}{|S_k|} \quad (k = 1, \dots, L)$ (3.38)

RBF 方式 : $o_k^l = 100 \times \sum_{a_l \in S_k} \frac{o_k^l(a_l)}{|S_k|} \quad (k = 1, \dots, L)$ (3.39)

GA 方式 : $O_k^l = 100 \times \sum_{a_l \in S_k} \frac{O_k^l(a_l)}{|S_k|} \quad (k = 1, \dots, L)$ (3.40)

なお、各実験における FIN 方式、RBF 方式、GA 方式におけるハフメタは以下通りである。

FIN: 学習係数 $\gamma = 0.001$, 1 入出力データに対する学習回数 = 1000, FSOM の出力ノード数 m (FIN の中間ノード数)=9(総ルール数= $9 \times 3 = 27$)

RBF: 学習係数 = 0.001, 1 入出力データに対する学習回数=1000, 中間ノード数 m (RBF の総ルール数= $9 \times 3 = 27$)

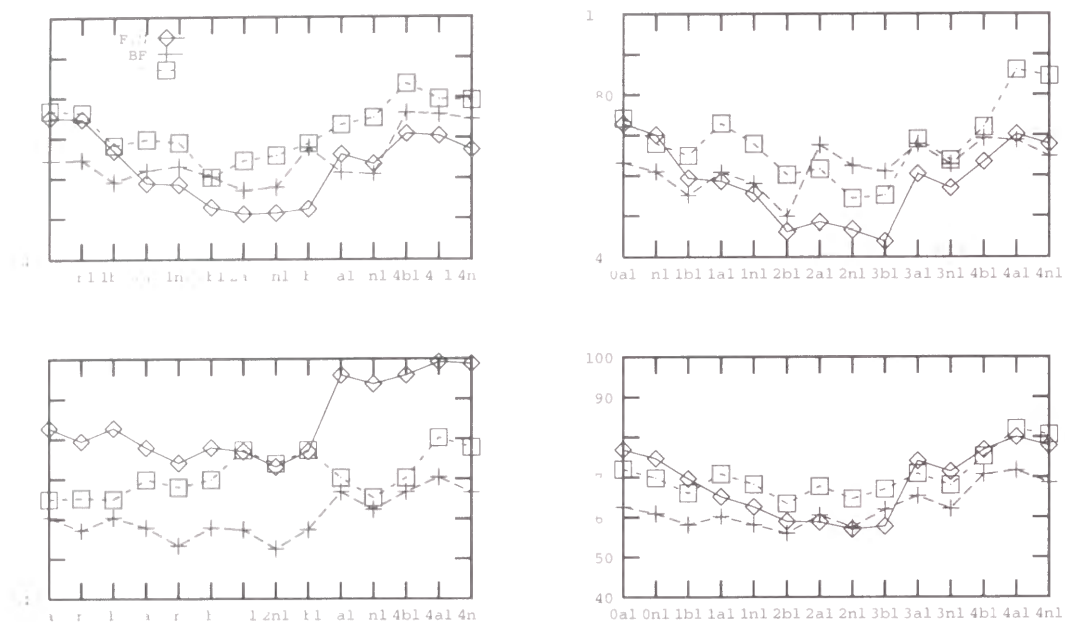


図 3.7: 2 の場合での各方式における正当率: 上左図: C_1 に対する正当率, 上右図: C_2 に対する正当率, 下左図: C_3 に対する正当率, 下右図: 平均正当率

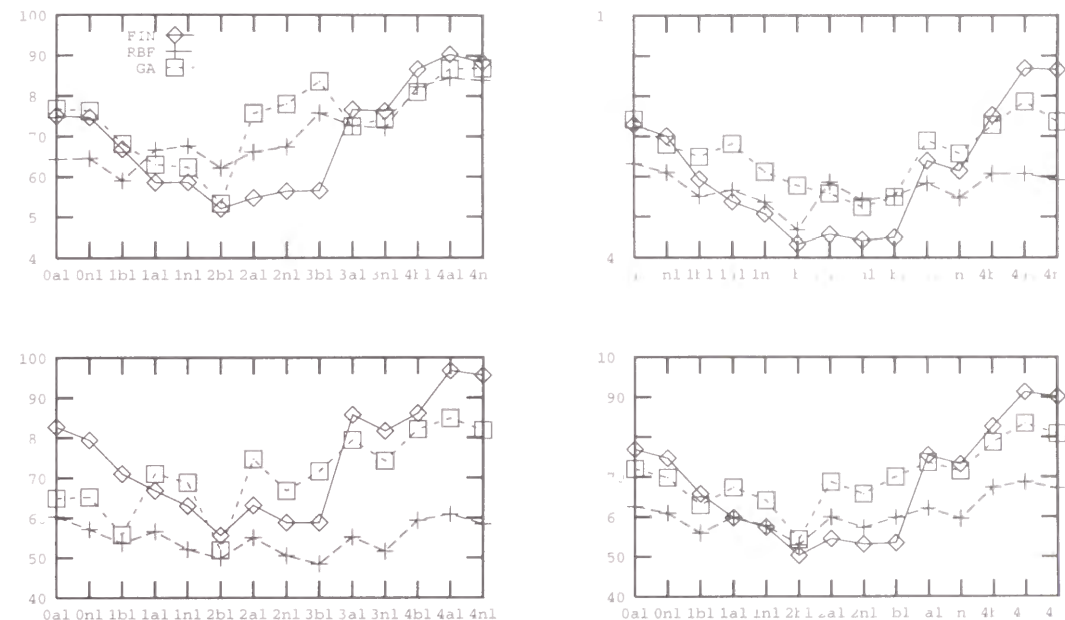


図 3.8: 3 の場合での各方式における正当率: 上左図: C_1 に対する正当率, 上右図: C_2 に対する正当率, 下左図: C_3 に対する正当率, 下右図: 平均正当率

FIN 方式							
		μ_i			幅		
		$\mu_{1,1}$	$\mu_{1,2}$	$\mu_{1,3}$	$\sigma_{1,1}$	$\sigma_{1,2}$	$\sigma_{1,3}$
step 0		2	0.09	0.08	1.05	0.44	1.04
step 1		1.52	0.07	0.1	1.09	1.14	1.1
step 2		1.38	0.3	1	1.71	1.6	1.73
step 3		0.43	0.04	1.45	1.09	1.37	1.04
step 4		0.07	0.1	2.07	0.07	0.04	0.04

RBF 方式					GA 方式									
		μ_i			σ_i			μ_i			$\sigma_{1,i}$			
		$\mu_{1,1}$	$\mu_{1,2}$	$\mu_{1,3}$	$\sigma_{1,1}$	$\sigma_{1,2}$	$\sigma_{1,3}$	$\mu_{1,1}$	$\mu_{1,2}$	$\mu_{1,3}$	$\sigma_{1,1}$	$\sigma_{1,2}$	$\sigma_{1,3}$	
step 0		1.1	0	0	0.83	3.4	0.03	3.4	2.12	1.85	0.19	8.39	2.14	4.39
step 1		1.11	0.07	0.82	3.7	0.4	3.4	2.08	1.77	0.19	8.05	2.13	2.2	
step 2		1.37	0.46	1.12	3.81	0.43	4.07	2.8	1.73	1.29	4.04	2.18	2.31	
step 3		1.1	0.71	1.32	3.85	0.24	4.07	2.12	1.7	1.58	7.55	2.25	2.38	
step 4		0.85	0.0	1.47	3.94	0.26	4.5	3.1	1.48	2.3	5.4	2.8	2.5	

表 3.2: 1 の場合における各方式でのメンバシップ関数のパラメータ推移

における各方式のメンバシップ関数を対比させたものである。また、図 3.10 は各ステップでの各方式におけるメンバシップ関数の中心 ($\mu_{1,1}, \mu_{1,2}, \mu_{1,3}$) の推移を表したものである。表 3.2 および図 3.10 に示されるように、入力データベクトルの平均が (2.0, 0.0, 0.0) から (0.0, 0.0, 2.0) に移動するにつれて、FIN 方式ではメンバシップ関数の中心も同じ方向に移動している。また、表 3.2 に示すように、FIN 方式では FSOM 章の学習により、メンバシップ関数の幅も 1.0 に近いものとなっている。図 3.9 における対比からも、他の方式に比べて FIN 方式がデータの傾向を確実に捉えていることがわかる。

3.4.2 FSOM における学習アルゴリズムの比較実験

本実験では、FSOM 章において第 3.2.2 章で与えた学習規則と第 3.2.3 章で与えたフuzzy集合論のそれぞれ学習アルゴリズムを用いた、FIN によるルール抽出に対する比較を行った。




図 3.9: 1 の場合における各方式での step1 のメンバシップ関数の対比 (上図: F_{1i1} , 下左図: F_{1i2} , 下右図: F_{1i3})

実験データ

実験データは、第 3.4.1 節と同様に 3 次元の入力値ベクトルと 3 種類の出力値を持ち (式 (1.1), (1.2) において $n = 3, l = 3$), 同一出力値を持つ入出力データの入力値ベクトルのガウス分布が段階的に変化するものと想定した。第 3.4.1 節の実験データは平均のみが変化するものであったが、本実験では分散も同時に変化するものと仮定した。表 3.3 および図 3.11 に、各出力値を持つ入出力データの入力値ベクトルにおける分散の変化を示す。

データ数は、1 つの出力値に対して 1 次元用に 30 個、2 次元用に 30 個、合計 1 ステップで 90 個のデータ、90 個のニューラルネットワークを用いる ($N = 90$, 各 S_i の要素数 30)。またここでは、上記データを $[0, 1]$ 区間に正規化して行った。本実験データは、中間のステップでは各出力を持つデータの入力ベクトル平均よりニューラルネットワークの最初および最終に比べて小さく、それに応じて分散も小さいという特徴を持つ。

本実験は、第 3.4.1 節と同様に、ステップ 0 からステップ 4 まで 90 個のデータと、90 個のニューラルネット




図 3.10: 1 の場合における各方式でのメンバシップ関数の中心の推移

	step 0	step 1	step 2	step 3	step 4
S_1 平均	(2.0, 0.0, 0.0)	(1.5, 0.5, 0.5)	(1.0, 1.0, 1.0)	(0.7, 1.5, 1.5)	(0.0, 2.0, 2.0)
S_2 平均	(0.0, 0.0, 2.0)	(0.5, 0.0, 1.5)	(1.0, 0.0, 1.0)	(1.5, 0.0, 0.7)	(2.0, 0.0, 0.0)
S_3 平均	(0.0, 2.0, 2.0)	(0.0, 1.5, 2.0)	(0.0, 1.0, 2.0)	(0.0, 0.5, 2.0)	(0.0, 0.0, 2.0)
各分布の分散	1.0	0.75	0.5	0.61	1.0

表 3.3: 実験用ニューラルネットワークにおける入力属性ベクトルの分布変化




図 3.11: 実験用入出力データにおける中心の変化

タに対する正答率を評価した。その後、各ステップの新たな傾向のデータに対して、学習データに対する前ステップの正答率、学習後正答率、未学習データに対する正答率を評価した。ステップ 0 以降では、各方式におけるパラメータの初期値は前ステップにおける学習後の値をそのまま継続した。また、出力 C_k を持つ出力データに対する正答率は式 (3.38) で定義されるものとした。

なお、本実験における FIN におけるパラメータは、いずれのアルゴリズムについても以下の通りである。

- 学習係数 $\eta = 0.01$ 、1 入出力データに対する学習回数 = 1000、FSOM の出力ノード数 m (=FIN の中間ノード数) = 25 (総ルール数 = $25 \times 3 = 75$)

実験結果

上記実験データに対する正当率の遷移を図 3.12 に示す。各グラフにおいて、先にも述べたように、FIN1 は式 (3.6)、(3.7) の学習則を用いた FIN による手法、FIN2 は式 (3.18)、(3.19)、(3.21) のフジィ競合学習則を用いた手法である。

- またこの手法について、各入力耐量ベクトル分布の間のユークリッド距離分散が小さくな






図 3.12: 各アルゴリズムにおける正当率 (上図: C_1 に対する正当率, 左下図: C_2 に対する正当率, 右下図: C_3 に対する正当率)

る中間ステップにおいて、正当率が減少した。その中で、学習後の学習データおよび未学習データに対する正当率は、フジィ競合学習を用いた手法のほうが安定しており、このステップにおいても 70% 以上を保った。初期と最終ステップではどちらの手法でも正当率は高く、フジィ競合学習を用いた手法では 90% 前後を示したが、クリスな学習則を用いた手法では中間ステップでの正当率がかなり劣る結果となった。

3.5 考察

以上の実験から以下の考察が得られる。

- FIN 方式は FSOM の教師無し学習により他のノードに依存しないクラスタリングを行う。つまり、FIN の学習には S_1 以外のノードの分布は全く関係ない。このため、上記実験でフジィ競合学習を用いた

より、 S_1 に対する出力は高い。このように、各入力属性ベクトルの中核ベクトルの距離が小さくなるにつれ、 S_k に対する出力は高くなる。また、 S_k の分布が重なり、各 FIN_k の出力が高くなると考えられる。逆に、分布の重なりが少なくなると出力は低くなる。従って、このように、他の方式に比べて正答率が高いと考えられる。

また、 S_k の分布が変動する場合、メンバシップ関数の形状はデータの分布に適した形で形状が鋭く、平坦になる。この場合、 FIN_k の S_k に対する出力が大きいと同時に、 S_k 以外のデータに対する出力は非常に小さい。この場合、 S_k の分布が変動しない場合はメンバシップ関数の形状はそれほど鋭くならない。この場合、 S_k に対する FIN_k の出力が大きいと同時に、 S_k 以外のデータに対する出力も、ある程度大きくなる。これは、分布が変化しない場合は S_k がローカルミニマムに囚われていることが原因と考えられる。

4.3.1.1 章の図 4.3.1.1 の場合においては FIN_2 、 FIN_3 の出力が FIN_1 に影響するため、正規化後の出力は、見かけ上 S_1 に対しては低く、 S_2 と S_3 に対しては高い。1 の場合においても FIN_3 の出力は FIN_1 、 FIN_2 に影響するため、正規化後の正答率は、見かけ上 S_1 と S_2 に対しては低く、 S_3 に対しては高い。3 の場合においても、データの傾向変動する場合、各 FIN の出力値自体は低いか、傾向値は低いか、捉えがたい。この場合、正規化した時点で他方式よりも高い正答率を示すと考えられる。

次に、RBF 方式、GA 方式では、各 RBI_k 、 POP の空間に S 以外のデータの分布も用いているため、異なる S_k の間でも分布の重なりのある程度の正答率を出していると考えられる。とくに、GA 方式は、この非定常環境に適する安定性 [19] により、RBF 方式よりもデータの傾向変動の度合いに依存せず安定した傾向抽出を行っていると考えられる。しかし、FIN 方式に比べて、抽出されるメンバシップ関数の形状は、データの分布に寄り変化が正確に反映したものではない。実際、図 3.2 に示すように、RBF 方式はメンバシップ関数の中心が S_1 、 S_3 の分布の中核ベクトルが載っている平面第 2 成分 = 2 の方向にずれ、この 4 成分の方向の幅が非常に小さくなっている。GA ではメンバシップ関数の中心が 1 方向にずれ、4 成分の方向の幅が大きくなっている。また、RBF、GA 共に、残りの 2 つの成分の方向に変化は FIN の場合より小さい。この幅が極端に大きくなっている。

これは、式 (3.32) と式 (3.33) のデータの分布に対する単純な自乗乗関数を用いているためであると考えられる。この場合、 S_k に対して大きい出力、 S_1 、 S_3 に対して小さい出力を実現させるために、結果として、各 1 成分に対して 4 成分の方向のずれが生じる。このように、このように、さらに、RBF 方式では、 S_2 と

S_3 に対して小さい出力を実現させるために、第 2 成分の幅が非常に小さい。RBF 方式、GA 方式の場合、逆にこの自乗乗関数の影響により、実際のデータの分布が正確に反映しない可能性がある。ある程度の正答率を得ているものと考えられる。

また、フージ競合方式がクリスプな競合方式に勝利結果となる原因としては、各値関数にエンタロピー項の導入により、FSOM 方式の出力データのメンバシップ関数の効率が上がり、より正確な予測に比べてデータの分布の変動、特に分散の変動に強いことが原因と考えられる。

第4章 実数値染色体と偏平均交叉による遺伝的 アルゴリズムを用いたファジィルール 抽出

4.1 はじめに

従来、ファジィ推論ルールの構築は手作業により成されていたが、第3章においても触れたように、ファジィネットワークや遺伝的アルゴリズムなどの機械学習を用いて入出力データサンプルから自動的にルール抽出を行う手法が、近年多数提案されている。とくに、最近では遺伝的アルゴリズム(GA)を用いた手法が多数提案されている[10, 15, 32]。

これらの手法は、あらかじめ与えられたルールの中で入力データの分割に最も適したものを選ぶ、もしくは簡略化ファジィ推論ルールにおける後件部の数値を決定することを目的としており、バイナリ符号化された離散値染色体を用いて、選択されるメンバシップ関数のラベルや、決定されるべき後件部の数値を表現している。しかし、入力空間のファジィクラスタリングの観点からは、データの分布に合わせてファジィメンバシップ関数のパラメータの厳密な調整に難しさがある。また、これらの手法ではビット列に対する1点もしくは多点交叉が用いられており、交叉処理そのものや個体適応度の計算に負荷が生ずる。連続値表現された染色体と平均値に基づく交叉を採用しているGAも存在する[7]が、この平均交叉は集団の多様性を保持しない。

本章では、実数値染色体符号化を用いるファジィクラスタリングに適した交叉「偏平均交叉」、およびこれを用いたGAによる自動的ファジィルール抽出法を与える。また、第3章と同様に、傾向が動的に変化するデータに対する既存手法との比較実験の結果を示す。

4.2 ファジィルール抽出のための遺伝的アルゴリズムにおける実数値

染色体符号化と偏平均交叉

4.2.1 実数値符号化

本章で与えるファジィルール抽出法は、第3章と同様に、式(1.1)で与えられる入出力データから式(1.3)、(1.4)の形式のルールを抽出することを前提とする。つまり、 k 番目のラベル C_k を持つ n 次元数値ベクトルの集合を m 個のガウス型ファジィ集合を用いてクラスタリングする。

既存のGAによるこの種のファジィクラスタリングでは、ルール前件部において事前に行きわたった有限個のメンバシップ関数の離散的ラベル、もしくは第3.1.1におけるFSOMとの比較実験で用いられたSimple GAによる手法のように、メンバシップ関数の数値パラメータを離散化してビット列に染色体として使い、これらのビット列に対してビット操作を行う。また、個体適応度は、与えられたベクトルが染色体に対応するファジィ集合に属する度合に基づいて計算される。この種のGAは、ビット列が数値パラメータに対応していることは認識されず、数値としては扱われない。

本章における手法は、基本的に第3.3.3章で示されたGAによるルール抽出法、同じく「あ」が、染色体符号化法として、以下に示される、1つのルール前件部における式(1.4)のガウス型メンバシップ関数のパラメータ群の配列を1つの染色体として扱う。

$$Ind_{ki} = (\mu_{ki1} \ \sigma_{ki1} \ \mu_{ki2} \ \sigma_{ki2} \ \dots \ \mu_{kin} \ \sigma_{kin}) \quad (i = 1, \dots, m, k = 1, \dots, L) \quad (4.1)$$

つまり、この場合においても1つのルールが1つの個体に対応する。また、同シングルトン形式の後件部“ c is C_k ”を持つ m 個のルール群 $\{Ind_{ki} : i = 1, \dots, m\}$ を1つの集団 POP_k とし、合計 L 個の集団 POP_1, \dots, POP_L を用いる。すなわち、 k 番目の集団 POP_k は k 番目のラベル C_k を持つ数値ベクトルをクラスタリングするためのファジィメンバシップ関数に対応する全この個体から成る。図4.1に、1つの集団構成を示す。

第3.3.3章でも示されたように、これらの各集団に対して、独立に遺伝的操作を行う。具体的には、式(3.33)、(3.34)に示された適応度に基づくルーレット戦略によって行われる。

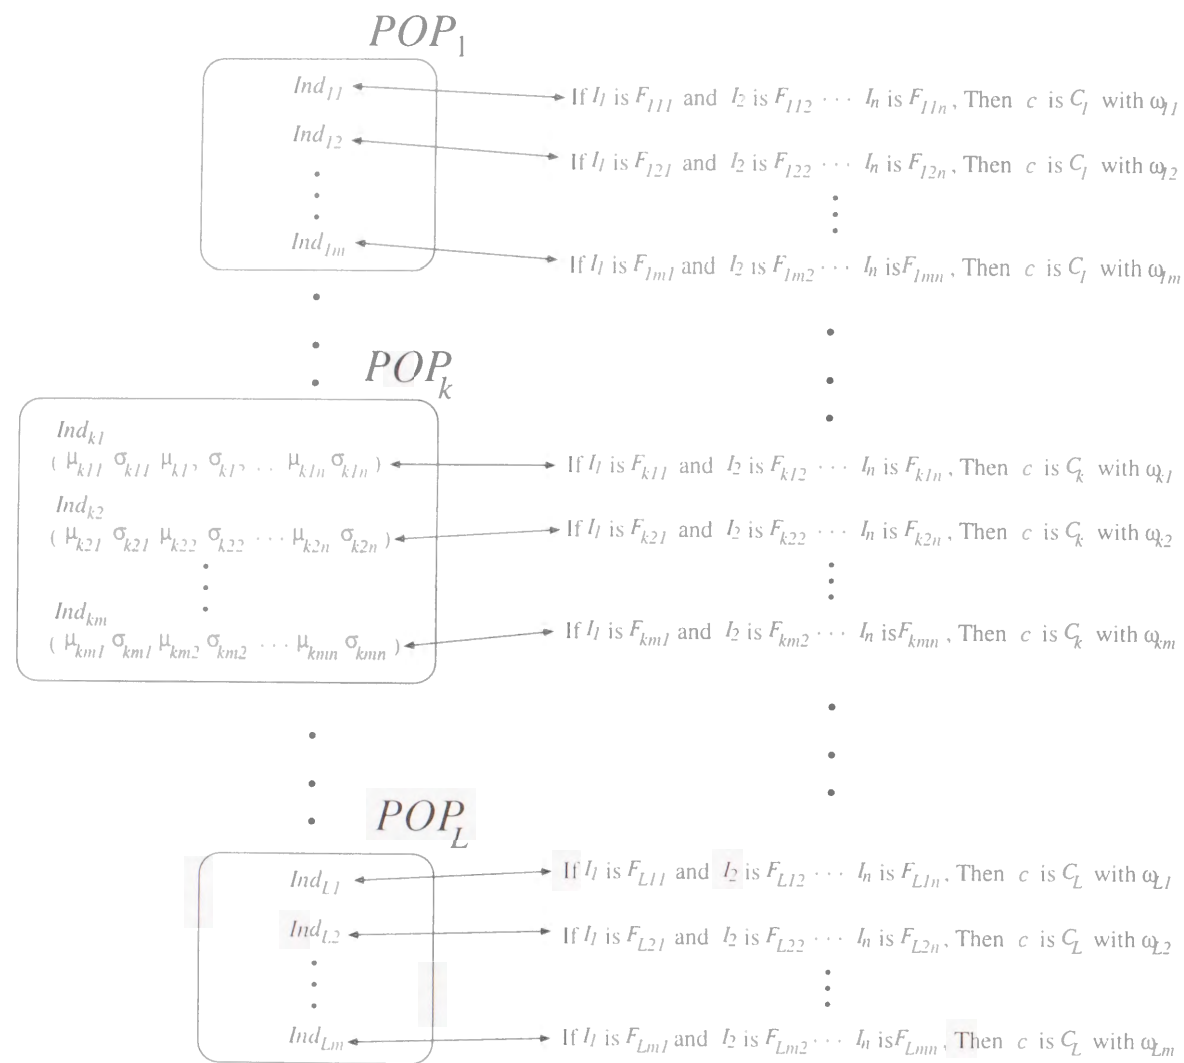


図 4.1: 実数値染色体 (GA) における集団構成

4.2.2 偏平均交叉

既存の GA においては、上記の配列は各数値パラメータを離散化することによりビット列に変換され、交叉は2つの親ビット列に対し1点もしくは多点を基点とする部分列入れ換えとして行われる。親の数値配列染色体の各遺伝子座における値を平均することにより1つの子孫の配列の値を決定する平均値交叉を採用している GA も存在する [7]。しかし、ファジィクラスタリングの観点から考えた場合、こ

れらの交叉法には、親のファジィメンバーシップ関数の適切な形状が次世代に継承されないという問題がある。

偏平均交叉 (Unfair Average Crossover: 以降 U'FAC' と略称) は上記の問題の1つの解決法として与えられる。上記の平均値交叉では、2つの親個体から1つの子孫が生成されるが、U'FAC' においては2つの親個体から2つの子孫が生成される。

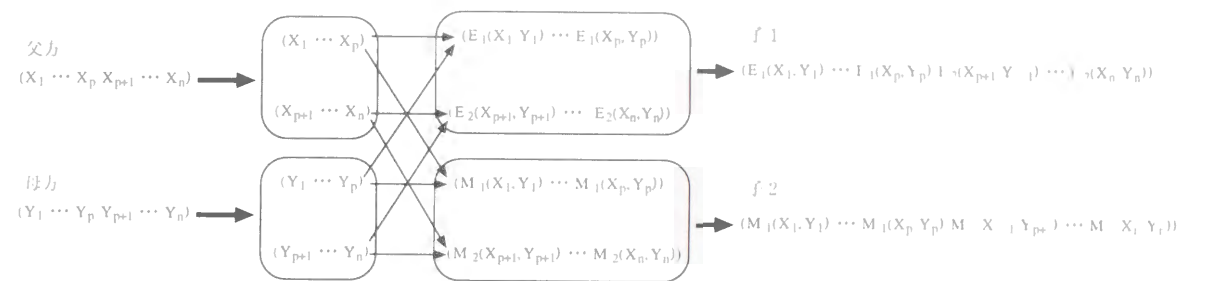


図 4.2: 偏平均交叉

U'FAC' では以下の4種類の2実変数関数 E_1 , E_2 , M_1 , M_2 を用いる。

$$\left. \begin{aligned} E_1(f, m) &= (1 + (1/a))f - (1/a)m \\ E_2(f, m) &= -(1/a)f + (1 + (1/a))m \\ M_1(f, m) &= (1 - (1/a))f + (1/a)m \\ M_2(f, m) &= (1/a)f + (1 - (1/a))m \end{aligned} \right\} (a: \text{実数値}, a > 2) \quad (4.2)$$

式 (4.2) におけるパラメータ a を遺伝率と呼ぶ。この遺伝率という語は量的遺伝学における「狭義の遺伝率」からのアナロジーである [6] が、厳密な定義は異なることを注記しておく。 f を父方個体染色体のある遺伝子座における値、 m を母方個体染色体の同じ遺伝子座における値とすると、 $E_1(f, m)$ は平均値から父方の値の方向に偏った値、 $M_1(f, m)$ は父方の値の方向から平均値に近付いた値、 $E_2(f, m)$ は平均値から母方の値の方向に偏った値、 $M_2(f, m)$ は母方の値の方向から平均値に近付いた値である。

図 4.2 に U'FAC' の手順を示す。まず、2つの親個体の数値配列染色体を任意に選択された1点で切り放す。次に、それぞれの部分配列の各座標に対して関数 E_1 , E_2 , M_1 , M_2 を適用し、新たな部分配列を生成した後、部分配列を接続して2つの子個体染色体の数値配列を生成する。式 (4.1) のパラメータを

個体 1 の形質と見なす時、個体 1 は親の形質を激しく、個体 2 は平均的に継承する形となる。

図 4.3 に平均値交叉および UFAC によるメンバシップ関数の形状の変化を示す。平均値交叉では、親個体 1 つか適切な特徴を持っていたとしても、子個体ではそれがほかされる。一方 UFAC では、親のメンバシップ関数とは厳密には異なるが、遺伝率に依存した形で 2 つの子個体のうち 1 つにある程度受け継がれる。また、平均から外れた子個体を生成することにより、集団の多様性が保たれる。




図 4.3: 平均値交叉および UFAC による親と子へのメンバシップ関数の形状変化

4.2.3 ファジイルール抽出への適用

本章の GA によるルール抽出は、基本的に第 3.3.3 章において示されたものと同じであり、以下の手順により行われる。

0. 式 (4.1) の個体染色体の実数値要素を初期化する。
1. 各集団 POP_k において、式 (3.33), (3.34) の適応度に基づくルーレット選択、UFAC による交叉、

染色体数値配列中の任意の要素をランダムな値と入れ換え、ここによる突然変異を行い、1 世代交替とする。

2. 1 を T 回繰り返す。ここで、 T は与えられた最大世代交替回数である。
3. 最終的に得られた適応度を式 (3.35) の形で正規化し、ファジイルール (4.3) の確信度を決定する。得られたルールの出力は式 (3.36), (3.37) によって与えられる。

4.3 動的環境におけるシミュレーションと評価

ここでは、第 4.2 章で与えた GA によるファジイルール抽出法の有効性を示すために、既存の GA による手法との比較実験の結果を与える。第 3.4.1 章と同様に、ここでは 3 つの入力属性と 3 種類の出力値を持つ式 4.1 の入出力データ ($n = L = 3$) を用いて実験を行った。

比較手法としては、第 3.4.1 章と同様に 2 値表現の染色体による Simple GA による手法と、本章における数値配列染色体に対して UFAC の代わりに平均値交叉を採用する手法を用いた。Simple GA の場合は、式 (4.1) の染色体数値配列の各実数値を 64 ビットのバイナリもしくはクレスコにより離散化した $64 \times 2 \times n$ の長さのビット列を個体染色体とした。各集団 POP_k に対する遺伝的操作として、選択は第 4.2 章と同様に式 (3.33), (3.34) に基づくルーレット選択、交叉は 1 点交叉、突然変異はビット反転を採用した。

4.3.1 実験 1

実験 1 では、第 1 世代から第 300 世代までは図 4.4(a) に示される入力属性分布を持つデータに GA を適用し、その後データの分布が急激に変化したと仮定して、第 301 世代から第 600 世代までは図 4.4(b) に示される新たな分布を持つデータに GA を適用した。各分布は分散 1 のガウス分布を持つデータで、1 つの出力値に対して 30 個の学習用データおよび 30 個のテスト用データ、つまり合計 90 個数の学習データと 90 個のテスト用データを用意した。また、学習用データに対して GA を適用しファジイルールを抽出した後、学習用データとテスト用データの両方に対して、分布が変化する直前の 300 世代目と変化後 300 世代を経た 600 世代目における正当性を評価した。




図 4.4: 実験 1 における入力属性ベクトルの分布

パラメータ設定	1	2	3	4	5	6	7	8	9	10	11	12
交叉確率	0.6	0.8	1.0	0.6	0.6	0.8	0.6	0.8	1.0	0.6	0.6	0.8
突然変異確率	0.01	0.01	0.01	0.1	0.5	0.1	0.01	0.01	0.01	0.1	0.5	0.1
エリート戦略の有無	無	無	無	無	無	無	有	有	有	有	有	有

表 4.1: 実験 1 において用いられたパラメータ

また、表 4.1 に示される 12 種類の遺伝操作のパラメータを用い、各パラメータでの GA に対する評価を行う。各パラメータ設定での GA において、式 (3.34) における選択圧力 sp (選択における個体間生存確率の差を決めるパラメータ) は 0.1、1 つの集団における個体数 (式 1.3 における m) は 20 とした (総個体数 = 20×3)。また、正当率は第 3.4.1 の場合と同様に、

$$C = 100 \times \frac{1}{3} \sum_{i=1}^3 \frac{1}{30} \sum_{a \in A_i} P(a) \quad (4.3)$$

と定義した。

表 4.2 に上記データに対する正当率の結果を示す。また、 $i=4.5, 4.6, 4.7, 4.8, 4.9$ に、式 (3.33) で定義される評価値 e_{ki} の各手法における平均値の遷移を示す。

以下に、正当率の結果における傾向に関して記述する。

エリート戦略を用いない場合での交叉確率の影響

表 4.2 のパラメータ設定 1 とその結果の図 4.5 に示されるように、交叉確率が小さい場合、UFAC による手法の正当率は分布変化前および変化後ともに他の手法に比べて 5 から 10% 高く、環境変動に対して高い適応能力を示した。しかし、表 4.2 のパラメータ設定 2, 3 とその結果の図 4.6 に示されるように、交叉確率が 0.8 以上の場合は、環境適応能力が低かった。Simple GA による手法の分布変化後における正当率は変化前より低く、しかも交叉確率に関係なく環境適応能力は低かった。平均値交叉による手法は、交叉確率 0.8 では UFAc による手法よりも高い正当率を示しているが、Simple GA による手法と同じ傾向を示した。




図 4.5: 実験 1 におけるパラメータ設定 1 の各 GA の評価値の遷移 (横軸: 世代数、縦軸: 評価値 e_{ki} の平均)

手法	1				2				3			
	学習		変化後		変化前		変化後		変化前		変化後	
	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ
SGA-b	61.74	61.44	39.29	40.68	63.18	63.62	39.75	37.72	64.43	62.88	40.69	40.66
SGA	64.24	61.30	54.99	54.61	57.07	56.89	32.33	32.68	54.65	54.49	43.43	43.98
RGA-av	64.64	65.44	52.83	52.47	72.53	73.92	53.00	53.85	68.94	69.75	54.91	56.03
RGA-uv3	66.69	66.90	61.35	61.55	66.85	67.66	53.85	55.12	69.35	70.61	62.72	62.50
RGA-uv4	66.66	71.35	66.96	70.62	70.06	71.43	57.18	57.46	66.36	67.49	52.45	51.71

手法	4				5				6			
	学習		変化後		変化前		変化後		変化前		変化後	
	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ
SGA-b	68.11	67.84	58.69	61.37	57.78	58.14	71.63	71.37	63.28	63.11	55.23	53.72
SGA	66.76	70.03	51.39	55.50	67.37	66.56	73.88	75.75	64.99	65.65	61.77	62.06
RGA-av	64.84	66.00	65.85	66.48	64.42	65.00	62.08	62.34	68.52	69.83	67.86	68.86
RGA-uv3	62.64	74.31	72.14	73.22	61.36	61.77	58.56	58.83	72.64	74.32	69.28	69.71
RGA-uv4	77.51	79.72	70.91	71.28	60.28	60.71	49.57	49.94	66.68	68.15	76.78	76.60

手法	7				8				9			
	学習		変化後		変化前		変化後		変化前		変化後	
	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ
SGA-b	64.81	63.67	33.14	33.54	54.51	54.48	32.04	32.69	52.71	52.81	35.08	36.25
SGA	59.34	56.64	49.51	50.57	63.13	64.55	18.03	16.75	59.83	60.44	31.81	32.01
RGA-av	69.54	63.98	56.41	55.83	72.82	74.05	34.06	34.08	67.15	69.68	63.77	63.47
RGA-uv3	71.54	72.67	60.07	61.54	76.27	77.67	74.90	75.40	73.62	74.79	58.59	60.48
RGA-uv4	70.54	71.62	67.14	68.04	69.36	70.74	72.47	73.29	68.74	69.80	66.89	67.13

手法	10				11				12			
	学習		変化後		変化前		変化後		変化前		変化後	
	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ	学習データ	テストデータ
SGA-b	55.56	54.67	60.71	62.73	68.64	68.94	66.37	66.28	64.67	64.44	49.17	50.63
SGA	56.64	56.46	62.38	61.61	63.85	64.28	68.66	69.20	62.27	61.98	57.24	59.12
RGA-av	66.64	77.83	84.59	88.74	57.38	59.51	57.75	58.12	64.71	65.65	68.20	68.76
RGA-uv3	70.64	72.64	73.64	74.89	53.24	54.14	58.08	57.41	74.32	76.01	84.10	84.85
RGA-uv4	66.44	69.26	63.17	74.11	59.24	59.42	58.08	58.15	64.25	64.87	73.64	74.37

表 4.2: 実験 1 の結果 (データは表 4.1 のパラメータ設定で、各 GA によるルール抽出法の正当率 (%) (SGA-b: ハイブリッド染色体による Simple GA, SGA-g: グレーコード染色体による Simple GA, RGA-av: 数値配列染色体と平均値交叉による GA, RGA-uv3: 数値配列染色体と遺伝率 $a = 3.0$ の UFAC による GA, RGA-uv4: 数値配列染色体と遺伝率 $a = 4.0$ の UFAC による GA)




図 4.6: 実験 1 におけるパラメータ設定 2 での各 GA の評価値の遷移

エリート戦略を用いた場合での交叉確率の影響

表 4.2 のパラメータ設定 8 とその結果の図 4.7 に示されるように、交叉確率が 0.8 の場合、UFAC による手法の正当率は他の手法に比べて分布変化前および変化後ともに高く、環境変動に対し高い適応能力を示した。平均値交叉による手法は分布変化前において UFAC による手法と同程度の高い正当率を示したが、分布変化後は約 30% 低くなり、環境適応能力は低かった。しかし、交叉確率が非常に高い場合は、分布変化後の正当率は UFAC による手法と同じくらい高くなった。Simple GA による手法はエリート戦略の導入により環境適応能力が低くなった。




図 4.7: 実験 1 におけるパラメータ設定 8 での各 GA の評価値の遷移

突然変異確率の影響

表 4.2 のパラメータ設定 1, 6 とその結果の図 4.8 に示されるように、突然変異確率が 0.1 の場合、すべての手法について分布変動に対する高い適応能力が見られた。とくに、バイナリコード染色体の Simple GA による手法、平均値交叉による手法、遺伝率 $\alpha = 3.0$ の UFAC による手法の分布変化後に対する正当率は、突然変異確率が 0.01 の場合に比べて 10% 前後高かった。しかし、表 4.2 のパラメータ設定 5 とその結果の図 4.9 に示されるように、突然変異確率が非常に高い場合は、数値配列染色体による手法の正当率は低かった。一方、Simple GA による手法の正当率は他の手法に比べて 10% 前後高かった。表 4.2 のパラメータ設定 10, 11, 12 に見られるように、エリート戦略が用いられる場合と用いられない場合の両方において、同じ傾向が見られた。




図 4.8: 実験 1 におけるパラメータ設定 1 での各 GA の評価値の遷移

UFAC による手法における遺伝率の影響

表 4.2 のパラメータ設定 1, 6, 7, 9 に示されるように、交叉確率が小さい場合、遺伝率 $\alpha = 3.0$ の UFAC による手法は遺伝率 $\alpha = 1.0$ の同手法に比べて、分布変化後の正当率が低かった。また、交叉、突然変異確率が高くエリート戦略が用いられない場合、および、非常に高い交叉確率、低い突然変異確率でエリート戦略が用いられる場合においても、同様の結果が得られた。しかし、表 4.2 のパラメータ設定 3, 8, 12 に見られるように、非常に高い交叉確率、低い突然変異確率でエリート戦略が用いられる場合、および、低い




図 4.9: 実験 1 におけるパラメータ設定 5 での各 GA の評価値の遷移

交叉確率でエリート戦略が用いられる場合では、遺伝率 3.0 の UFAC による手法は遺伝率 $\alpha = 1.0$ の同手法に比べて分布変化前、変化後ともに正当率が高かった。

4.3.2 実験 2

実験 2 においては、入力属性ベクトルの分布が、実験 1 の変化前の状態から徐々に実験 1 の変化後の状態まで、表 4.3 および図 4.10 に示される形で 30 世代ごとに段階的に移り変わると仮定した。これらのデータはガウス分布に基づくとした上で、各手法を適用した。図 4.3 に示される各分布に対して、実験 1 と同様に 90 個の学習用データと 90 個のテスト用データを用い、学習用データからフジシールルを抽出、入力属性分布が変化する 30 世代ごとにテスト用データに対して式 (4.3) で定義される正当率を評価した。

本実験では、まずすべての手法において交叉確率 0.6、突然変異確率 0.01 の状態で比較を行った。また、交叉確率 0.6、突然変異確率 0.5 でのバイナリコード染色体と Simple GA による方、交叉確率 0.5、突然変異確率 0.1 での数値配列染色体と平均値交叉、UFAC による方法との間で比較を行った。各手法におけるこれらのパラメータは、実験 1 における 12 種類のパラメータの中で最も高い正当率を示したものである。

図 4.11 以上に、すべての手法において交叉確率 0.6、突然変異確率 0.01 の場合の各手法の正当率

	C_1 に対応する 性質、トール	C_2 に対応する トール性、トールの 中心	C_3 に対応する 各分布における 中心	分散
0	(2, 0, 0)	(0, 0, 2)	(0, 2, 2)	1
1	(1.9, 0.1, 0.1)	(0.1, 0.1, 9)	(0.1, 1.9, 2)	0.95
2	(1.8, 0.2, 0.2)	(0.2, 0.1, 8)	(0.2, 1.8, 2)	0.9
3	(1.7, 0.3, 0.3)	(0.3, 0.1, 7)	(0.3, 1.7, 2)	0.85
4	(1.6, 0.4, 0.4)	(0.4, 0.1, 6)	(0.4, 1.6, 2)	0.8
5	(1.5, 0.5, 0.5)	(0.5, 0.1, 5)	(0.5, 1.5, 2)	0.75
6	(1.4, 0.6, 0.6)	(0.6, 0.1, 4)	(0.6, 1.4, 2)	0.7
7	(1.3, 0.7, 0.7)	(0.7, 0.1, 3)	(0.7, 1.3, 2)	0.65
8	(1.2, 0.8, 0.8)	(0.8, 0.1, 2)	(0.8, 1.2, 2)	0.6
9	(1.1, 0.9, 0.9)	(0.9, 0.1, 1)	(0.9, 1.1, 2)	0.55
10	(1, 1, 1)	(1, 0, 1)	(0, 1, 2)	0.5
11	(0.9, 1.1, 1.1)	(1.1, 0, 9)	(0.9, 1.1, 2)	0.52
12	(0.8, 1.2, 1.2)	(1.2, 0, 8)	(0.8, 1.2, 2)	0.51
13	(0.7, 1.3, 1.3)	(1.3, 0, 7)	(0.7, 1.3, 2)	0.56
14	(0.6, 1.4, 1.4)	(1.4, 0, 6)	(0.6, 1.4, 2)	0.58
15	(0.5, 1.5, 1.5)	(1.5, 0, 5)	(0.5, 1.5, 2)	0.61
16	(0.4, 1.6, 1.6)	(1.6, 0, 4)	(0.4, 1.6, 2)	0.68
17	(0.3, 1.7, 1.7)	(1.7, 0, 3)	(0.3, 1.7, 2)	0.76
18	(0.2, 1.8, 1.8)	(1.8, 0, 2)	(0.2, 1.8, 2)	0.84
19	(0.1, 1.9, 1.9)	(1.9, 0, 1)	(0.1, 1.9, 2)	0.92
20	(0, 2, 2)	(2, 0, 0)	(0, 0, 2)	1

図 1.3. 図 1.2 における入力属性ベクトルの分布の遷移 (本実験では各ステップ 30 世代ずつ)

※ 図 1.3, 1.4, 1.5, Simple GA 方式, 遺伝交叉確率 0.6, 突然変異確率 0.5, 数値配列染色体において交


雑確率 0.8, 遺伝的異質性 0.1 の場合 (2) 各手法 (2) 対し, 遷移を示す。実験 1 と同様に, Simple GA

方式 (2) の場合 (2) 対し, 染色体として使用し, EFAC の遺伝率は 3.0 と 1.0 の 2 種類を

使用している。

図 1.11 図に示されるように, 突然変異による小さい場合, EFAC による場合 (2) 対し, 30% の

図 1.10: 入力属性ベクトルの分布の遷移



70% の間を変化させた。平均値交叉による手法では 10% から 60% の間を変化し, Simple GA では 70% 以上で 30% 程度にまで減少した。この場合, EFAC による手法は他の手法に比べて環境変動に対する高い適応能力を示した。また, 遺伝率 3.0 の EFAC による手法は 1.0 の同手法に比べて後半の段階 (2) 対し, 染色体として使用し, EFAC の遺伝率は 3.0 と 1.0 の 2 種類を

図 1.11 図に示されるように, 突然変異確率 0.5 の場合, Simple GA 方式




図 4.11: 表 2 の 3 手法の性能の推移 (上図: 各手法において交叉確率 0.6, 突然変異確率 0.01 の場合, 下図: Simple GA 方式において交叉確率 0.6, 突然変異確率 0.5, 数値配列染色体において交叉確率 0.8, 突然変異確率 0.1 の場合)

方式の正当率は 60% から 80% の間を変化し, UFAC による手法では 50% から 80% の間を変化した。しかし, バイナリコード染色体での Simple GA および平均値交叉による手法では, 40% から 65% の間への変化であった。この場合, グレーコード染色体での Simple GA および UFAC による手法が他の手法に比べて環境変動に対する高い適応能力を示した。




図 4.12: 遺伝率 $a = 4.0$ の UFAC による手法におけるメンバシップ関数 F_{121} の遷移




図 4.13: 遺伝率 $a = 3.0$ の UFAC による手法におけるメンバシップ関数 F_{121} の遷移

図 4.12, 4.13, 4.14, 4.15 に, 交叉確率 0.6, 突然変異確率 0.01 の場合の各世代におけるメンバシップ関数 F_{121} の遷移を示す。ラベル C_1 に対応する入力量性ベクトルの分布の中心が (2.0, 0.0, 0.0) から (0.0, 2.0, 2.0) に移動するにつれ, UFAC による手法でのメンバシップ関数は同じ方向に移動した。平均値交叉による手法でもメンバシップ関数は同じ方向に移動したが, 関数の幅が異なる分布に




図 4.14: 平均値交叉による手法におけるメンバシップ関数 F_{121} の遷移




図 4.15: Simple GA による手法におけるメンバシップ関数 F_{121} の遷移 (左図: バイナリ染色体, 右図: Gray Code 染色体)

合っていない。Simple GA による手法では、幅を除いて関数はほとんど移動しなかった。UFAC による手法よりメンバシップ関数を入力ベクトルの分布を厳密に反映したものではないが、正当性は他の方法に比べて高い。これは、選択に用いた評価値 c_k (3.33) のデータに対する単純な自乗関数であり、データ分布と厳密に反映したものではないことが原因と考えられる。

4.4 考察

以上の結果から以下の議論が導かれる。

交叉確率が非常に高い、もしくは遺伝率が低い場合は、UFAC は現在の環境に適した染色体の平均に近い子孫を多く生成し、それらは選択を通じて次世代に生育する。従って、平均値交叉を用いた場合と同様に集団の多様性が低くなり、ルール抽出が環境の急激な変化に追従出来ない。一方、一度環境が激変し平均から外れた子孫の適応度が高くなれば、エリート戦略によりそれらが生き残り、また、頻繁に変動する環境においては、交叉確率が高いことにより変化する環境に適した子孫が生成される。従って、UFAC によるルール抽出は他の手法に比べて環境変動に対する高い適応能力を持つ。平均値交叉は平均からはずれた子孫を生成しないので、エリート戦略の有無に関係無く、ルール抽出は UFAC による手法ほど高い適応能力を持たない。

また、突然変異は数値配列染色体とビット列染色体のいずれにおいても集団の多様性を保つ。さらに、UFAC による手法の場合、高い突然変異確率、高い遺伝率、およびエリート戦略の使用の組合せが環境変動に対するより高い適応能力を導く。しかし、数値配列染色体の場合、非常に高い突然変異確率は図 4.9 に見られるような評価値平均の振動を引き起こし、集団が収束しない。これは、突然変異として染色体上の数値の任意の値による置き換えを行っているからである。一方、ビット列染色体の場合は、今回の実験のように少ない集団数では遺伝的浮動現象が起こりやすいため、環境変動に対する適応のためには高い突然変異率が必要となる。

手法	時間
数値配列染色体と UFAC	約 2 分
数値配列染色体と平均値交叉	約 2 分
バイナリコード染色体と Simple GA	約 10 時間
グレーコード染色体と Simple GA	約 11 時間

表 4.1: 各手法において 600 世代交替に要した時間

さらに、ビット列染色体による手法では、数値配列染色体による手法に比べて非常に多くの計算時間が必要となる。表 4.1 に、SpareStation 5 を用いた上記シミュレーションで各手法において 600 世代交替に要した時間を示す。表 4.1 において示されるように、Simple GA による手法は数値配列染色体に

アルゴリズムは300回以上の計算時間を要した。これは、適応度の計算に多くの時間が費やされたためであり、
各個体の fitness 値の計算における実数値 u の間の変換に時間がかかっているためである。

第5章 ハイブリッドシステムを用いたファジィ ルール抽出

5.1 はじめに

生物の環境に対する適応過程には、1 個体の生涯レベルでの u による適応と、世代を跨ぐ適応¹ がある進化がある。工学的には、前者はニューラルネットワークによって、後者は遺伝的アルゴリズムによって実現される。本稿においても、データからのファジィ推論規則の適応的抽出を目的として、第3章においてニューラルネットワークによる方式を、第4章において遺伝的アルゴリズムによる方式を採り立てた。一方、近年、数多くのニューラルネットワークと遺伝的アルゴリズムのハイブリッドモデルが提案されている ([17], 3 章を参照)。

本章¹ では、第3章で与えた FSOM と第4章で与えた数値配列染色体と UFAC を用いた GA の両方を組み合わせたハイブリッドシステムを与え、両者の特性を活かした、動的環境に対する式 (1.3), (1.4) のファジィ推論規則を抽出する手法を与え、シミュレーションによりその有効性を検証する。

SOM タイプのニューラルネットワークと GA のハイブリッドモデルは既に幾つか提案されている [12, 31] が、ここでのモデルはファジィルール抽出に特化されたものである。

また、本モデルにおいて、個体から u によって得た特性を染色体に直接反映させるメカニク的手法²、 u によって得た特性が適応度評価にのみ関連する従来のダーウィンの手法との比較についても議論する。

¹ これは [3] に従って、 u によって得た特性を染色体に直接反映させるメカニク的手法と区別する。

5.2 学習と進化のハイブリッドモデル

5.2.1 FSOM と実数値染色体 GA のハイブリッドモデル

現在までに、数多くのニューラルネットワークと遺伝的アルゴリズムのハイブリッドモデルが提案されており、その中に SOM 型のニューラルネットワークとのハイブリッド化も含まれている。

図 5.1(a) に Harp と Samad によるモデル [12] を示す。このモデルでは、SOM の構造決定と結合係数の最適化に GA が用いられており、1 つの SOM が 1 つの染色体で表現される。

図 5.1(b) に Toth と Lorincz によるモデル [31] を示す。このモデルでは、SOM は GA の外部パラメータ (すなわち、突然変異確率等) の空間をクラスタリングするために用いられており、SOM の各出力ノードが GA の 1 つの部分集団に対応する。

図 5.1(c) に本章でのモデルを示す。本モデルでは、FSOM 群と数値配列染色体による GA の部分集団群との間に 1 対 1 の対応があり、さらに、各 FSOM の出力ノードと対応する部分集団の個体との間に 1 対 1 の対応がある。

本章の目的は、式 (1.1) の入出力データから式 (1.3) のファジィルールを抽出することであるので、これに基づいて以下に構成される。

まず、第 3.3.1 章と同様に、式 (1.3) の推論規則群のうち、後件部が同じシングルトン構造を持つ m 個の規則

If I_1 is $F_{k,1}$ and I_2 is $F_{k,2}$ and ... and I_l is $F_{k,l}$, Then c is C_k with weight ω_{ki}

$$\sum_i \omega_{ki} = 1 \quad (i = 1, \dots, m)$$

に対して、1 つの FSOM を対応させる。この FSOM (以降、 $FSOM_k$ と略称) は、 $F_{k,j}$ を i 番目の中間ノード、 j 番目の入力ノード間のファジィ結合係数として持つ。式 (1.3) の推論規則群において、同じシングルトン形式の後件部が合計 L 個存在するので、規則群全体に対して合計 L 個の FSOM $\{FSOM_1, \dots, FSOM_L\}$ が対応する。

次に、第 4.2.1 章と同様に、1 つのルール前件部における式 (1.4) のガウス型メンバシップ関数パラ

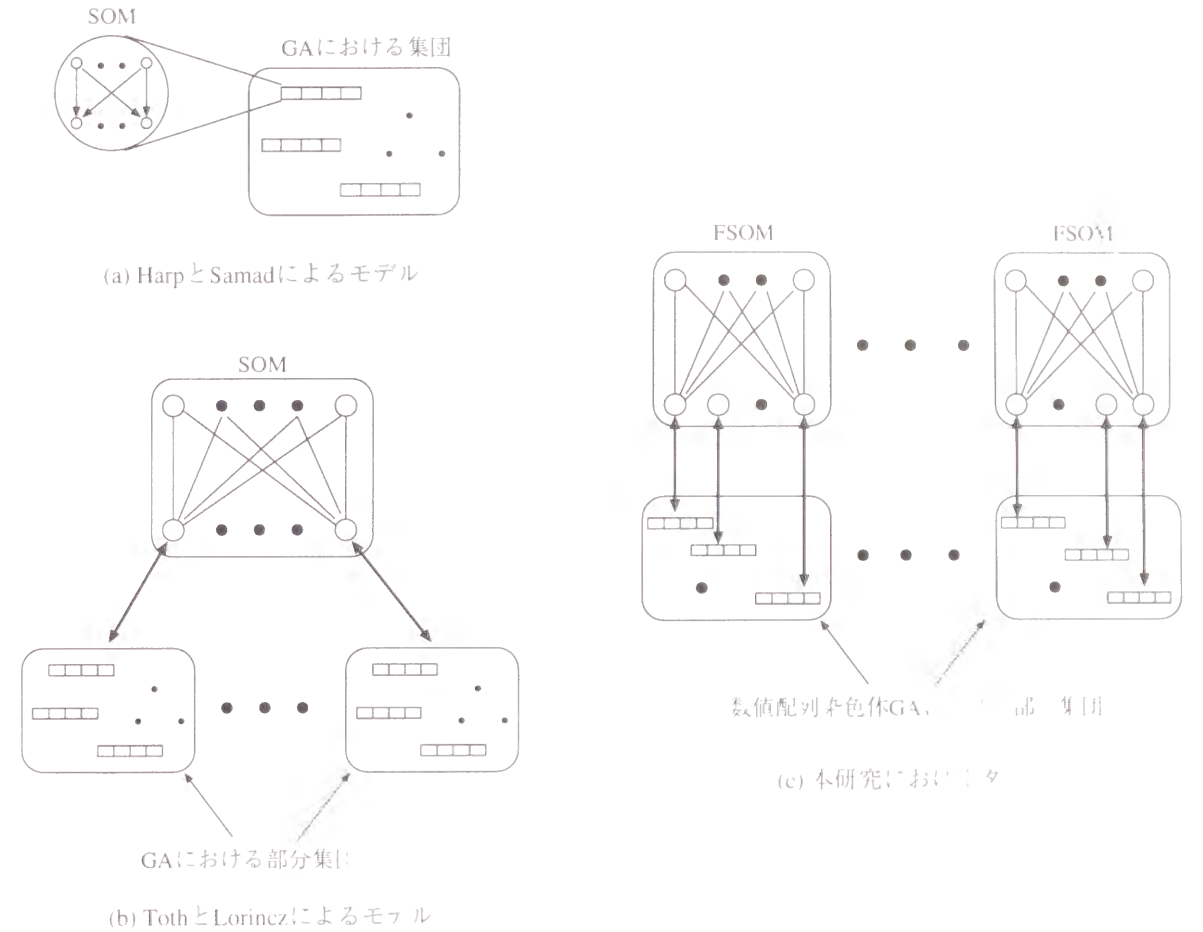


図 5.1: SOM 型ニューラルネットワークと GA のハイブリッドモデル

メータ群の配列を、

$$Ind_i = (\mu_{k,1}, \sigma_{k,1}, \mu_{k,2}, \sigma_{k,2}, \dots, \mu_{k,l}, \sigma_{k,l}) \quad (i = 1, \dots, m, k = 1, \dots, L)$$

をそれぞれ 1 つの染色体として扱う。つまり、この場合においても 1 つのルールから 1 つの個体、メタ個体として扱う。また、同じシングルトン形式の後件部が C_k を持つ m 個のルール群 $\{Ind_k, i = 1, \dots, m\}$ を 1 つの部分集団 POP_k とし、合計 L 個の部分集団 POP_1, \dots, POP_L を用意する。 k 番目の部分集団 POP_k は k 番目のファジィメンバシップ関数を持つ数値ベクトルをクラスタリングするためのファジィメンバシップ関数に対応するメタ個体からなる。

図 5.2: FSOM による数値染色体 GA のハイブリッドモデルを示す。これらの対応では、後件

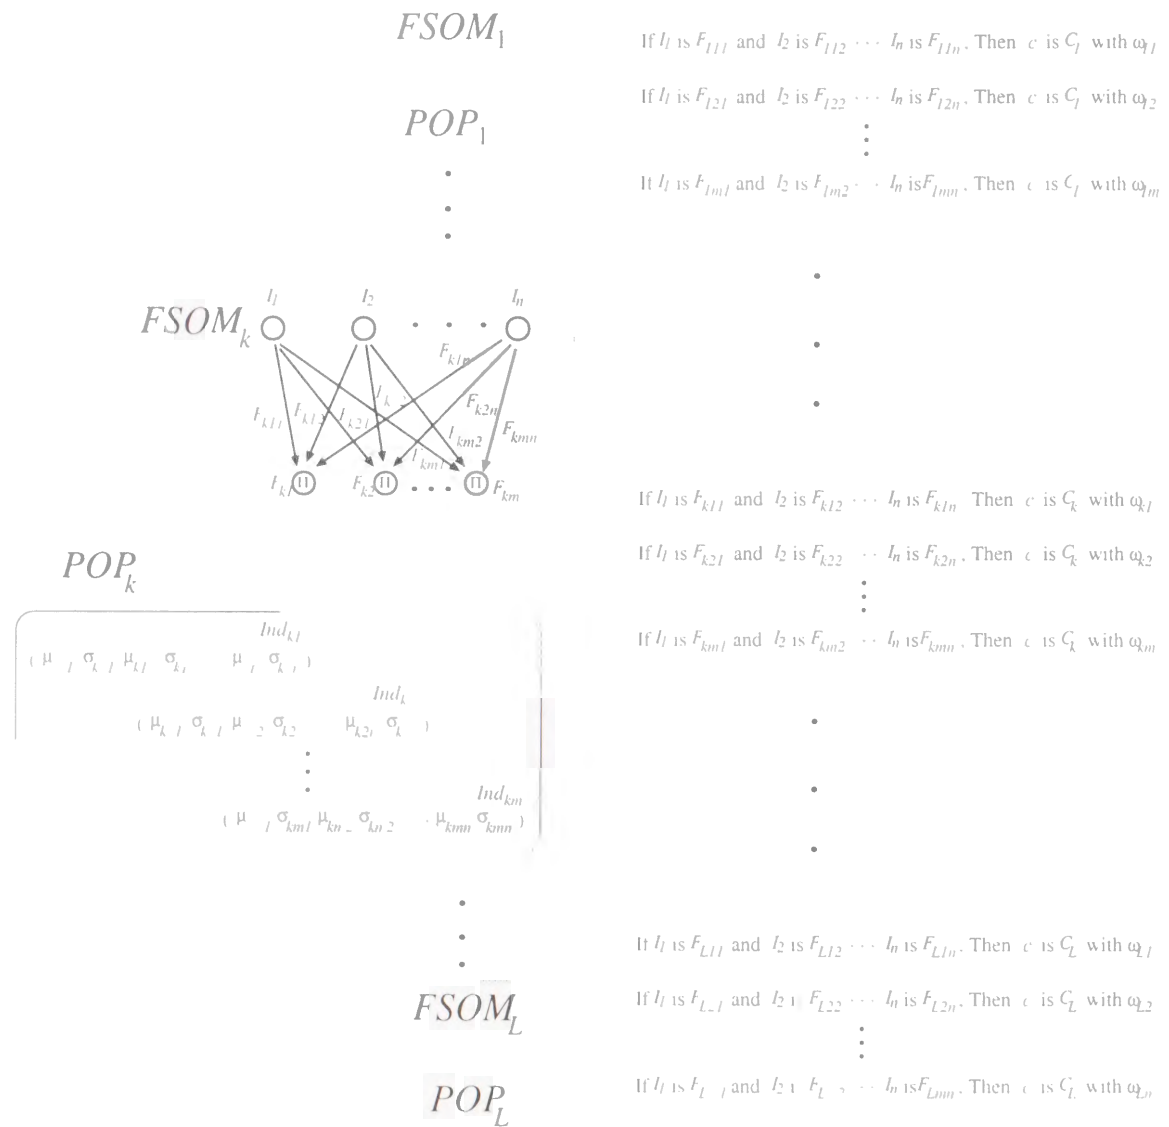


図 5.2: FSOM による数値染色体 GA のハイブリッドモデル

部 c is C_k 、あるいは番号 i のルール i に対して、 $FSOM$ の i 番目の出力ノードと POP の i 番目の個体 Ind_i が対応付けられる。ここで、これら染色体と遺伝子型、 $FSOM$ の出力結果を表現型とみなす。つまり、数値配列の個体、 $FSOM$ の出力の初期状態より、出力結果に基づいて個体適応度を評価し、適

行うことにより、入出力データからファジィルールを抽出する。これは、式 (3.33), (3.34) による適応度計算において数値配列染色体の値を用い、数値配列染色体の値 \times 初期値より $FSOM$ の出力の結果として得られたファジィ結合係数を用いるということである。

5.2.2 ダーウィンの手法とラマルクの手法によるファジィルール抽出

学習と進化のハイブリッドモデルにおいては、進化論において議論となることが「獲得形質の遺伝」が問題となる。現在の進化生物学においては、基本的に、個体とその生涯において環境によって獲得した特徴が次世代の遺伝子に組み込まれるというラマルキズムは誤りであるとされ、個体の遺伝子の変化と集団での遺伝子頻度の変化は、あくまでランダムな突然変異と選択によるものであるとするダーウィニズムが主流である。しかし、学習が間接的な形で進化に影響するという考えは Baldwin 効果として知られており、この効果の有効性に対するモデルの研究が行われている。

[1] では、各個体が環境からの入力に対して行動を決定するためのニューラルネットワークを持つマルチエージェントシステムにおいて、遺伝的アルゴリズムによってニューラルネットワークの設定・強化を行い、異なる係数の組合せにより、仮想環境でのシミュレーションを行い、進化、および各々単体の場合よりも組合せの場合がエージェントの仮想環境での生存率が高いことを示している。また、[11] では、固定長のビット列で表現された染色体個体の集団において、特定の個体のみが最大の適応度を持ち、それ以外の個体は均一に低い適応度を持つ問題を設定し、遺伝子頻度の世代に対する差分方程式を立て、最大適応度個体に対応する遺伝子頻度の変化を数値計算により求めている。この際に、適応度評価の段階でランダム探索による学習の効果を導入し、最終的に必ずしも進化を促進する結果が得られることを示している。

一方、工学的な視点からは、必ずしも実際の進化生物学的に従うことはせず、ラマルキズムを用いたマルチエージェントシステムも考慮される [37]。[2] では、関数最適化問題に対して、遺伝的アルゴリズム、ラマルクの手法による学習過程を併用した手法を用い、学習結果が遺伝子に直接反映するラマルクの手法を用いない従来のダーウィンの手法との比較実験を行い、ラマルクの手法が勝るという結果を報告している。また、[36] では、ニューラルネットワークで表現された個体のニューラルネットワークが進化・学習する問題において、ラマルクの手法とダーウィンの手法との比較実験を行い、静的な環境ではラマルク型が環境に馴染み、動的な環境ではダーウィンの型が環境変動にも対応して安定であることが示されている。

Figure 1 illustrates the genetic algorithm for fuzzy inference. The process starts with an input/output data set $S = \{S^{(l)} = (a_{l1}, \dots, a_{ln} : c_l) \mid$. This data is distributed to multiple parallel processing units (labeled 1 to L). Each unit receives input data (a_{l1}, \dots, a_{ln}) and an initial value (初期値). The input data is processed by a fuzzy inference system (FS_l) to produce a result $c_l = C_l$. This result is then used by a population (POP_l) to calculate a fitness (適応度計算). The fitness is used to update the population (遺伝的演算) and to reflect back on the input data (染色体への反映 (ラマルクの手法の場合)). The final result (学習結果) is output from the system.

1. 式 (4.1) の数値配列をランダムに初期化し、各 POP_k の染色体の数値と対応する $FSOM_k$ のフジ結合係数に写す.
2. 各 POP_k ($k = 1, \dots, L$) において、FSOM のメンバシップ関数のパラメータに基づき、適応度計算し、ルーレット選択を行う. その後、TAC とランダム数値入れ換えによる突然変異を行う.
3. 各 $FSOM_k$ ($k = 1, \dots, L$) において、対応する POP_k の染色体の数値をフジ結合係数に基づき、ファジ競合学習によりパラメータを D 回更新する (D は与えられた学習回数).

ここで、第 3.3 章と同様に、 $FSOM_k$ に与えられるデータは S_k のみに属する $S^{(1)}$ の入力属性ベクトル a_i であり、それ以外の a_i は無視する.

4. ダーウィンの手法の場合は 5 に jump する. ラマルクの手法の場合は、各 POP_k の染色体に対応する $FSOM_k$ の学習後のパラメータを写す.
5. 2 から 4 を T 回繰り返す (T は与えられた世代交替回数).
6. 最終的に行われた適応度を式 (3.35) の形で正規化し、フジルール (1.3) の確信度を決定する. 得られたルールの出力は式 (3.36), (3.37) によって与えられる.

本章においても、第3章、第1章と同様に動的環境における有効性を検証するための比較実験を行った。ここでの比較対象は、第3章、第1章で紹介されたFSOM、GAの単体モデルによる方法である。実験データは、第4.3.2章において用いたデータと同じものを使用し、つまり、入出力データの入力属性ベクトルのガウス分布か、表4.3および図4.10に示される形で段階的に変化する仮定で、各ステップでの90個の学習データに対して、FIN単体による方式、GA単体による方式、ハイブリッドモデルによる方式を適用し、90個のテスト用データに対して4.3で定められる正当性を評価する。なお、表4.3の各ステップにおいて、FIN単体方式ではFSOMにおける結合係数の更新を30回、GA単体方式は世代数を30回、ハイブリッドモデル方式ではFSOMにおける結合係数の更新を30世代、

を3回行った。また、第3章、第4章での実験と同様に、学習および世代交替においては、前のステップでの最終状態を次のステップでの初期状態とした。各手法において、学習係数 $\gamma=0.01$ 、交叉確率 $=0.8$ 、突然変異確率 $=0.01$ 、同一後件部を持つルールの総数 $m=25$ とした。なお、本実験ではFSOMの学習則は(3.18)、(3.19)、(3.21)のフーシ競合学習を用いた。

図5.4に結果を示す。グラフの各数値は10回の試行における各ステップでの平均正当率を示す。




図 5.4: 各手法の平均正当率

強いデータの傾向変動に対して学習係数が小さいため、FSOM単体による方式では前半ステップで正当率が低く後半ステップで高くなり、それに対してGA単体による方式では正当率の変動が少なく、第3章、第4章における実験と同様に非定常環境における安定性が示された。

ハイブリッドモデルによる方式では、ラマルク的手法・ダーウィンの手法と間で異なる結果が示さ

れた。ダーウィンの手法では、環境が変動するにつれて正当率が減少し、本実験データに対しては適応出来なかった。一方、ラマルク的手法ではFSOM単体による方式とGA単体による方式の両方の様相が現れた。FSOMによる手法と同様に、初期ステップでの正当率はGAによる方式に劣るものの、ハイブリッドにおけるGAの効果のため、ステップ3ではほぼ同じ正当率を示した。その後、FSOMの学習効果により、FSOM単体方式と同様に後半ステップではGA単体方式を上回る正当率を示した。

図5.5に、各手法によるメンバシップ関数の1つ(F_{112})の遷移を示す。ラマルク的手法はこのハイブリッド

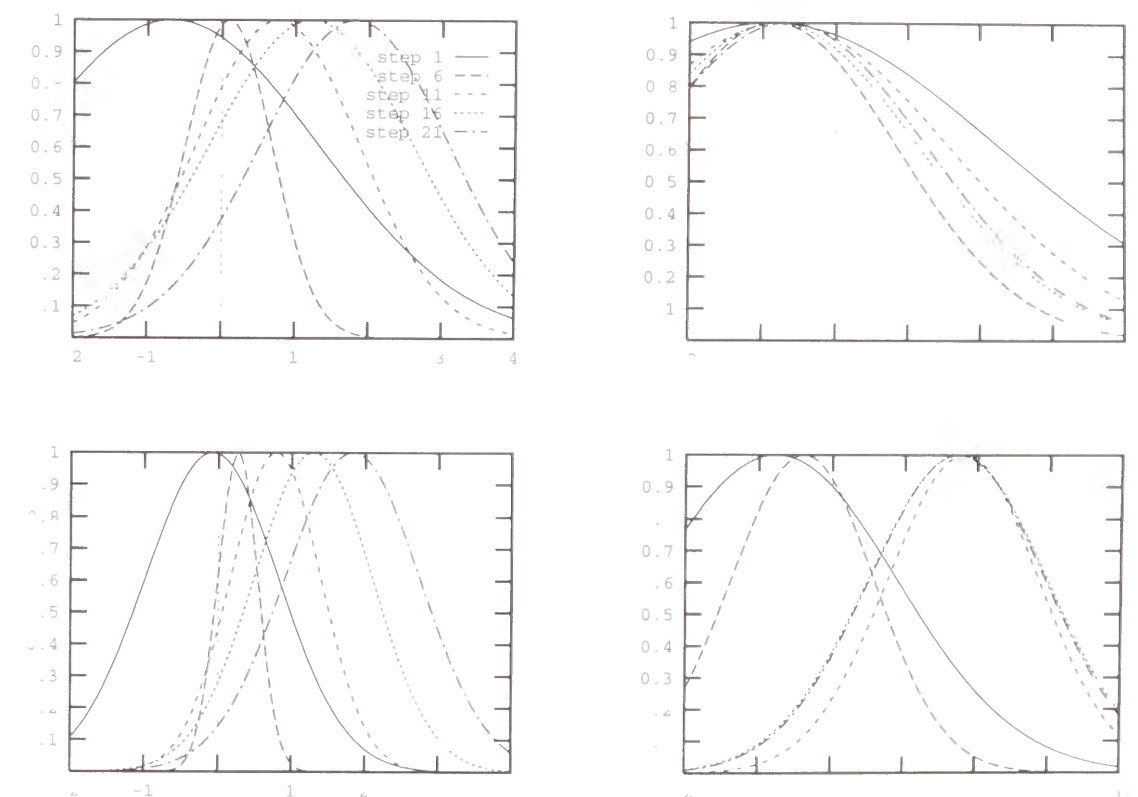


図 5.5: 各手法におけるメンバシップ関数 F_{112} の遷移: 上左図: ラマルク的手法でのハイブリッドモデルによる方式, 上右図: ダーウィンの手法でのハイブリッドモデルによる方式, 下左図: FSOM 単体方式, 下右図: GA 単体方式

モデルとして FSOM 単体方式におけるメンバシップ関数は、他の方式に比べて図 4.3 に示される環境変動に沿って豊移したか、ダーウィンの手法でのハイブリッドモデルではほとんど変化せず、これが正当性の低下に繋がっている。

5.4 考察

以上の結果は、ラマルクの手法によるハイブリッドモデルが FSOM と GA の両方の特性を持っていることが小さい。FSOM においては、データの分布を直接反映する評価関数に基づいてパラメータ調整が行われ、このメンバシップ関数がより鮮鋭となる。一方、それはローカルミニマムと過学習の問題を生み、正当性が激しく変化する。第 3.4.1 章、第 4.3 章においても触れたように、GA は動的環境に対する適応能力を持ち、この正当性はより安定的であるが、データ分布を直接的には反映しない自乗誤差関数を個体の評価に用いているため、そのメンバシップ関数の形状が実際の分布とは異なる。ラマルクのハイブリッドモデルでは、結果が染色体に直接写されるため、両者の特徴が直接的に補間し合う。一方、ダーウィンの手法では、結果は個体評価のみに用いられ、FSOM と GA が直接補間し合うことがない。ダーウィンの法を用いたモデルにおいても、Baldwin 効果などの学習と進化の協調による有効性か、静的環境 [11, 17]、動的環境 [36] の両方において示されているが、本実験ではこの種の効果は観察されなかった。原因としては、本実験においては、データ傾向の速い変動に対して学習回数や世代交替数が少なく、ダーウィンの手法と学習と進化の相互補助が起こるには環境変動が速すぎたことが考えられる。つまり、以上の結果は、人間の嗜好の傾向を抽出するような急速な動的環境での工学的応用については、ラマルクの手法はダーウィンの手法に勝る可能性を示唆している。

第6章 おわりに

6.1 まとめ

本稿では、入力属性の分布傾向が変動する入出力データから、フuzzy If-Then ルール形式の知識として傾向を抽出することを目的として、Fuzzy Self Organizing Map、数値配列染色体と偏平均交叉を用いた遺伝的アルゴリズム、およびそれらのハイブリッドによる学習と進化のモデルによるフuzzy ルール抽出法を与え、シミュレーションによりその有効性を検証した。

第 2 章では、数値確信度が付与された形式のファジィ If-Then ルールにおいて、数値確信度に対して 2 通り (直接確信度と間接確信度) の解釈を考え、各々の場合に対して T ノルムによる Zadeh, Baldwin, 塚本の推論法を適用し、その性能を検証した。また、後件部メンバシップ関数の集合集合が有限集合の場合に、複数の結論の合成規則として max 合成もしくは加算合成を用いた時、各種推論法において、後件部がシングルトン形式の確信度付きルールの結論が従来形式のルールの結論と一致するための T ノルム、含意関数の条件を示した。結論として、T ノルムが左連続 (例えば、 \min, \times) である関数が $I(a, b) = a * b$ で与えられていれば、従来形式のルールと数値確信度付きシングルトン型ルールは、推論法に Zadeh, Baldwin, 塚本のいずれの方式を用いても等価であることが示され、本稿で使用する数値確信度付きシングルトン型ルールと直接法による推論法の汎用性が小さされた。

第 3 章では、適応的ルール抽出の 1 つとして、フuzzy クラスタリングを行なうモデルとして FSOM とフuzzy ルールを表現するニューラルネットワーク FNN を与え、RBF, GA と比較してシミュレーションを行ない、その有効性を検証した。結果的に、FNN 方式は、入出力データに対して各出力値に対応する入力ベクトルの分布がある程度の距離を保ちながら段階的に変化する場合には、適応的ルール抽出方式として RBF などの Feedforward 型ニューラルネットワークや GA より有効であると考えられる。また、FNN 方式は他の方式に比べてメンバシップ関数の形状がデータに適応して安定している。

ルール抽出結果が人間に理解しやすいという特徴を有し、意志決定支援の観点から有効である。

第4章では、遺伝的アルゴリズムにおける染色体の数値配列表現とそれに応じた偏平均交叉、およびこれらによるフジシ If-Then ルール抽出法を与え、既存の Simple GA などとの比較シミュレーションを行い、その有効性を検証した。結果として、本稿における知識抽出などの実数値パラメータの問題に対しては、数値配列染色体表現は Simple GA などのビット列染色体表現に比べて計算時間や環境変動に対する安定性に優れ、さらに数値配列染色体に対する偏平均交叉の使用は集団の多様性を保ち、環境変動に対する集団の適応能力に優れていると考えられる。

第5章では、第3章と第4章の手法のハイブリッドモデルを与え、それぞれの単体方式との比較シミュレーションを行い、その有効性を検証した。結果として、データの傾向が急速に変動する場合には、適応能力としては個々の単体方式より優れていると考えられる。

6.2 今後の課題

今後の課題としては、まず全体論として、本稿で問題とするような傾向変動を持つデータのための統計的手法の比較、現実の問題におけるデータによる有効性検証、後件部が実数値・フジジ変数の場合への拡張が考えられる。

次に、今回は FSOM の際には教師無し学習を用いたが、正答率向上のため第3.3章で主張した学習処理の低減を犠牲にして、LVQ の方法を用いた教師付学習へ拡張することも考えられる。

また、数値配列染色体と偏平均交叉における1つの理論的問題として、数値配列染色体による GA の理論的挙動解析がある。Simple GA は固定長のビット列を染色体として用いるため集団の状態空間が有限集合であり、有限マルコフ連鎖の理論を用いた多くの解析結果が報告されている [33, 18, 8, 30, 28, 9]。その中で、交叉、突然変異確率の集団収束性に対する条件などが議論されている。また、ビット列染色体に比べ交叉の理論的解析がより行われている [4]。数値配列染色体と UFAC に対しても、同様の理論的解析がなされなければならないが、数値配列染色体の場合は集団の状態空間は無限非可算集合であり、Simple GA の場合には異なる解析の困難さが付きまとう。数値配列染色体の問題に対しては既に、非可算集合を渡るマルコフ過程の理論を用いた有限個体集団の収束に関する結果 [29] や、無限個

体集団を仮定した集団分布関数の遺伝的操作による変化に関する結果 [25, 26] が報告されている。著者自身も無限個体集団の仮定を用いて、交叉が集団分布関数に与える変化に関して幾つかの解析結果を出している [20, 19] が、選択なども含めた遺伝的操作全体による集団分布の変化の解析にはまだいいない。現在1つの方法論として、式 (4.1) の数値パラメータを個体の量的形質と看做し、集団における平均や分散を生物学の観点、つまり量的遺伝学 [10, 6] における知見を用いて解析することが考えられる。

さらに、学習と進化のハイブリッドモデルに関して幾つかの問題が残されている。本論のシミュレーションでは、ラマルク的手法がダーウィンの手法に勝るという結果となったが、[36] において指摘されているように、工学的にダーウィンの手法がラマルク的手法に勝る状況が存在する可能性は無視できない。モデルの有効性を明らかにするためには、さらなる比較実験に加えて、上記の GA における集団ダイナミクスと、[11] において行われているような学習の影響を織り込んだ集団ダイナミクスの理論的解析が必要である。

参考文献

- [1] D. H. Ackley and M. L. Littman. Interactions Between Learning and Evolution. In C. G. Langton, C. Taylor, J. D. Farmer, and S. Rasmussen, editors, *Artificial Life II*, pp. 487–509. Addison-Wesley, 1991.
- [2] D. H. Ackley and M. L. Littman. A Case for Lamarckian Evolution. In C. G. Langton, editor, *Artificial Life III*, pp. 3–10. Addison-Wesley, 1991.
- [3] J. C. Bezdek, E. C. Tsao, and N. R. Pal. Fuzzy Kohonen Clustering Networks. In *Proc. IEEE International Conference on Fuzzy Systems*, pp. 1035–1043, 1992.
- [4] L. B. Booker. Recombination Distributions for Genetic Algorithms. In *FOGA '92, Proceedings of Workshop on the Foundations of Genetic Algorithms and Classifier Systems*, pp. 29–44. Morgan Kaufmann, 1992.
- [5] L. L. Chung and L. Lee. Fuzzy Competitive Learning. *Neural Networks*, Vol. 7, No. 3, pp. 539–551, 1994.
- [6] J. F. Crow. 基礎集団遺伝学. 培風館, 1989. (安田徳一訳).
- [7] L. Davis. *HANDBOOK OF GENETIC ALGORITHMS*. Van Nostrand Reinhold, 1990.
- [8] L. F. Davis and J. C. Principe. A Markov Chain Framework for the Simple Genetic Algorithm. *Evolutionary Computation*, Vol. 1, No. 3, pp. 269–288, 1993.
- [9] H. Dawid. A Markov Chain Analysis of Genetic Algorithms with a State-Dependent Fitness Function. *Complex Systems*, Vol. 8, pp. 407–417, 1994.
- [10] D. S. Falconer. 量の遺伝学入門. 蒼樹書房, 1993. (田中嘉成・野村哲郎共訳).
- [11] J. F. Fontanari and R. Meir. The Effect of Learning on the Evolution of Asexual Populations. *Complex Systems*, Vol. 4, pp. 401–414, 1990.
- [12] S. A. Harp and T. Samad. Genetic Optimization of Self-Organizing Feature Maps. In *Proc. IJCNN'91*, Vol. 1, pp. 341–346, 1991.
- [13] T. Kohonen. 自己組織化と連想記憶. シュブリンガー・フュアラーク東京, 1993. (中谷和夫訳).
- [14] B. Kosko. *NEURAL NETWORKS AND FUZZY SYSTEMS*. Prentice Hall, 1992.
- [15] M. A. Lee. On Genetic Representation of High Dimensional Fuzzy Systems. In *Proc. ISMIR-NAFIPS'95*, pp. 752–757, Maryland, Sept. 1995.
- [16] R. P. Li and M. Mukaidono. A maximum entropy approach to fuzzy clustering. In *Proc. FUZZ-IEEE/IFES'95*, pp. 2227–2233, 1995.
- [17] M. Mitchell and S. Forrest. Genetic Algorithms and Artificial Life. *Artificial Life*, Vol. 1, pp. 267–289, 1994.
- [18] A. E. Nix and M. D. Vose. Modeling genetic algorithms with Markov chains. *Annals of Mathematics and Artificial Intelligence*, Vol. 5, pp. 79–88, 1992.
- [19] T. Nomura. An Analysis on Crossovers for Real Number Chromosomes in an Infinite Population Size. In *Proc. International Joint Conference on Artificial Intelligence (IJCAI-97)*, Vol. 2, pp. 936–941, 1997.
- [20] T. Nomura. An Analysis on Linear Crossover for Real Number Chromosomes in an Infinite Population Size. In *Proc. International Conference on Evolutionary Computation (ICEC'97)*, pp. 111–114, 1997.

- [21] T. Nomura and M. Miyoshi. An Adaptive Rule Extraction with the Fuzzy Self-Organizing Map and a Comparison with Other Methods. In *Proc. ISU MA-VAFIPS'95*, pp. 311-316, Maryland, Sept. 1995.
- [22] T. Nomura and T. Miyoshi. Numerical Coding and Unfair Average Crossover in GA for Fuzzy Rule Extraction in Dynamic Environments. In T. Furuhashi and Y. Uchikawa, editors, *Fuzzy Logic, Neural Networks, and Evolutionary Computation (Lecture Notes in Artificial Intelligence 1152)*, pp. 55-72, Springer, 1996. (Reviewed).
- [23] T. Nomura and T. Miyoshi. An Adaptive Fuzzy Rule Extraction Using Hybrid Model of the Fuzzy Self-Organizing Map and the Genetic Algorithm with Numerical Chromosomes. *Journal of Intelligent and Fuzzy Systems*, 1998. (to appear).
- [24] L. Poggio and L. Girosi. Networks and the Best Approximation Property. Technical report, MIT A.I. Laboratory and Center for Biological Information Processing in Whitaker College, 1989.
- [25] X. Qi and F. Palmieri. Theoretical Analysis of Evolutionary Algorithms With an Infinite Population Size in Continuous Space. Part I: Basic Properties of Selection and Mutation. *IEEE Transactions on Neural Networks*, Vol. 5, No. 1, pp. 102-118, 1994.
- [26] X. Qi and F. Palmieri. Theoretical Analysis of Evolutionary Algorithms With an Infinite Population Size in Continuous Space. Part II: Analysis of the Diversification Role of Crossover. *IEEE Transactions on Neural Networks*, Vol. 5, No. 1, pp. 120-129, 1994.
- [27] J. R. Quinlan. Induction of Decision Trees. *Machine Learning*, Vol. 1, pp. 81-106, 1986.
- [28] G. Rudolph. Convergence Analysis of Canonical Genetic Algorithms. *IEEE Transactions on Neural Networks*, Vol. 5, No. 1, pp. 96-101, 1994.
- [29] G. Rudolph. Convergence of Evolutionary Algorithms in General Search Spaces. In *Proc. ICC'96*, pp. 50-54, Nagoya, May 1996.

- [30] J. Suzuki. A Markov Chain Analysis on A Genetic Algorithm. In *Proc. ICCA'93*, pp. 146-153, 1993.
- [31] G. J. Jóth and A. Lőrincz. Genetic Algorithm with Migration on Topology Conserving Maps. In *Proc. ICNA'93*, Vol. 3, pp. 168-171, 1993.
- [32] M. Valenzuela-Rendon. The Fuzzy Classifier System: A classifier System for Continuously Varying Variables. In *Proc. 4th ICCA*, pp. 346-353, 1991.
- [33] M. D. Vose and G. E. Lipins. Punctuated Equilibria in Genetic Search. *Complex Systems*, Vol. 5, pp. 31-44, 1991.
- [34] T. Yamaguchi, T. Takagi, and I. Mita. Self-organizing control using fuzzy neural networks. *International Journal of CONTROL*, Vol. 56, No. 2, pp. 415-439, 1992.
- [35] 陳啓浩, 柳原 二郎, 川瀬 達. 各種フuzzy推論法の間関係について. *日本ファジ学会誌*, Vol. 4, No. 6, pp. 1200-1208, Dec 1995.
- [36] 佐々木貴宏, 所真理雄. 進化的エージェント集団への動的環境への適応. *コンピュータソフトウェア*, Vol. 14, No. 4, pp. 33-46, 1997.
- [37] 山村雅彦, 小林重仁. 遺伝的アルゴリズムの工業的応用. *人工知能学会誌*, Vol. 9, No. 4, pp. 506-511, 1994.
- [38] 水本雅晴. フuzzy制御の改善法 (VII) - フuzzyインクルトン型推論法・代数積・加算・重心法・評価性 -. 第9回フuzzyシステムシンポジウム論文集, pp. 313-316, May 1993.
- [39] 石淵久生, 野崎賢, 山本直久, 田中英夫. フuzzy識別システムにおけるルール拡張のための置換操作. 第9回フuzzyシステムシンポジウム論文集, pp. 125-128, May 1993.
- [40] 中西利八郎. 遺伝的アルゴリズムによるフuzzy制御. *システム/制御/情報*, Vol. 38, No. 11, pp. 613-618, 1994.

- [11] 田中英夫, フラズィーデータ解析, システム制御情報学会セミナー「遺伝アルゴリズム ニューラル ネット フラズィーの新しい展開を探る」テキスト, pp. 43-52, Sept. 1993.
- [12] 土屋敏夫, 松原行幸, 長町三生, 商品発注支援システムにおける知識獲得手法 - Genetic Algorithm を用いたフラズィー IF-THEN ルールのパラメータの決定 -, 第8回ファジィシステムシンポジウム論文集, pp. 215-218, May 1992.
- [13] 馬野元秀, 岡本宏隆, 鳩野逸生, 田村坦之, 河内 三三夫, 梅津祐久, 木下淳一, ID3に基づくファジィ・ルールの抽出とその推論法, 第9回ファジィシステムシンポジウム予稿集, pp. 858-860, 1993.
- [14] 本多中一, 大甲有生, フラズィー工学入門, 海文堂, 東京, 1989.
- [15] 野村竜也, 数値確信度付きファジィルールへの各種推論法の適用およびシングルトン型ルールと従来型ルールとの等価性に関する検証, 電子情報通信学会論文誌 A, Vol. J79-A, No. 10, pp. 1734-1741, 1996.
- [16] 野村竜也, 三好力, Fuzzy if then Rule 抽出のためのニューラルネットおよび遺伝的アルゴリズムの構成, 電気学会第4システム情報化研究会資料, No. HS-95-19, pp. 71-80, 1995.
- [17] 野村竜也, 三好力, Fuzzy Self-Organizing Map を用いた適応的ルール抽出法と他方式との比較, 日本フラズィー学会誌, Vol. 8, No. 2, pp. 347-357, 1996.
- [18] 野村竜也, 三好力, 実数符号化と偏平均交叉を用いたGAによるファジィルール抽出, 第11回ファジィシステムシンポジウム論文集, pp. 221-224, July 1995.
- [19] 和田健之介, システム進化論 - 遺伝的アルゴリズムの基礎 (1), *Computer Today*, No. 47, pp. 49-61, 1992.
- [20] 桜井茂明, 三木大, 帰納学習によるフラズィー決定木の生成, 電気学会論文誌 C, Vol. 113, No. 7, pp. 488-494, 1993.
- [21] 川瀬吉, 柳原 二郎, フラズィー推論における間接法について, 電子情報通信学会論文誌 A, Vol. J77-A, No. 3, pp. 530-537, 1994.

本研究に関する公表文献

学会誌論文

- 野村竜也, 三好力, Fuzzy Self-Organizing Map を用いた適応的ルール抽出法と他方式との比較, 日本ファジィ学会誌, Vol. 8, No. 2, pp. 347-357, 1996.
- 野村竜也, 数値確信度付きファジィルールへの各種推論法の適用およびシングルトン型ルールと従来型ルールとの等価性に関する検証, 電子情報通信学会論文誌 A, Vol. J79-A, No. 10, pp. 1734-1741, 1996.
- T. Nomura and T. Miyoshi, An Adaptive Fuzzy Rule Extraction Using Hybrid Model of the Fuzzy Self-Organizing Map and the Genetic Algorithm with Numerical Chromosomes, *Journal of Intelligent and Fuzzy Systems*, 1998, (to appear).

書籍

- T. Nomura and T. Miyoshi, Numerical Coding and Unfair Average Crossover in GA for Fuzzy Rule Extraction in Dynamic Environments. In T. Furubashi and Y. Uchikawa editors, *Fuzzy Logic, Neural Networks, and Evolutionary Computation (Lecture Notes in Artificial Intelligence 1152)*, pp. 55-72, Springer, 1996, (Reviewed).

国際会議

- T. Nomura and M. Miyoshi, An Adaptive Rule Extraction with the Fuzzy Self-Organizing Map and a Comparison with Other Methods, In *Proc. ISU/MA-VAFIPS'95*, pp. 311-316, Maryland, Sept. 1995.
- T. Nomura and T. Miyoshi, Numerical Coding and Unfair Average Crossover in GA for Fuzzy Clustering and their Applications for Automatic Fuzzy Rule Extraction, In *Proc. IEEE/Nagoya University WWW'95*, pp. 13-21, 1995.
- T. Nomura and T. Miyoshi, An Adaptive Fuzzy Rule Extraction Using Hybrid Model of the Fuzzy Self-Organizing Map and the Genetic Algorithm with Numerical Chromosomes, In *Proc. Fourth International Conference on Soft Computing (IZUKA'96)*, Vol. 1, pp. 70-73, 1996.
- T. Nomura, An Analysis on Linear Crossover for Real Number Chromosomes in an Infinite Population Size, In *Proc. International Conference on Evolutionary Computation (ICEC'97)*, pp. 111-114, 1997.
- T. Nomura, A Proposal of Interpretations on Numerical Degrees of Confidence for Fuzzy If-Then Rules and a Mathematical Verification of Properties under Various Reasoning Methods, In *Proc. First International Conference on Knowledge-Based Intelligent Systems (KES'97)*, Vol. 2, pp. 542-549, 1997.
- T. Nomura, An Analysis on Crossovers for Real Number Chromosomes in an Infinite Population Size, In *Proc. International Joint Conference on Artificial Intelligence (IJCAI-97)*, Vol. 2, pp. 936-941, 1997.

大会・研究会等

- 野村竜也, 三好力, Fuzzy Self-Organizing Map を用いた対応的ルール抽出, 電気学会論文誌, 1994, 114(10), pp. 37-41, 1994.

- 野村竜也, 三好力, Fuzzy Self-Organizing Map を用いた対応的ルール抽出, 日本神経回路学会全国大会講演論文集, pp. 78-79, 1994.
- 野村竜也, 三好力, Fuzzy if-then Rule 抽出のためのニューラルネットおよび遺伝的アルゴリズムの構成, 電気学会産業システム情報化研究資料 HS-95-19, pp. 71-80, 1995.
- 野村竜也, 三好力, 実数符号化と偏平均交叉を用いたGAによるフuzzyルール抽出, 第11回フジシステムシンポジウム予稿集, pp. 221-224, 1995.
- 野村竜也, 三好力, GAにおける数値的染色体符号化と偏平均交叉及びその自動的フuzzyルール抽出への応用, 第5回フuzzy・ワークショップ in 名手論文集, pp. 1-7, 1995.

謝辞

本論文の作成にあたり，終始御指導，御鞭撻を賜りました京都大学大学院情報学研究科の片井修教授に，深甚な謝意を申し上げます．

また，本論文の作成に関して様々な御支援，御指導を賜りましたATR 人間情報通信研究所第6研究室の下原勝利室長，シャープ株式会社ソフトウェア研究所の小松純一所長に，深く感謝致します．

さらに，本研究を行なうにあたり，終始御指導，御鞭撻を賜りました鳥取大学工学部の三好力助教授に，深く感謝致します．